



UNIVERSIDADE FEDERAL DO MARANHÃO
Programa de Pós-Graduação em Engenharia Elétrica

Josélio da Conceição Cruz

**Proposta de um Modelo Preditivo para Eventos
de Rampa de Vento Utilizando *Random Forests***

São Luís
2024

Josélio da Conceição Cruz

Proposta de um Modelo Preditivo para Eventos de Rampa de Vento Utilizando *Random Forests*

Dissertação submetida à Coordenação do
Curso de Pós-Graduação em Engenharia
de Eletricidade da UFMA como parte
dos requisitos para obtenção do título de
Mestre em Engenharia Elétrica na área de
concentração de Sistemas de Energia.

Orientador: Prof. Dr. Denisson Queiroz Oliveira

Coorientador: Prof. Dr. Francisco Leite de Albuquerque Neto

São Luís

2024

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Diretoria Integrada de Bibliotecas/UFMA

Cruz, Joselio da Conceição.

Proposta de um Modelo Preditivo para Eventos de Rampa de Vento Utilizando Random Forests / Joselio da Conceição Cruz. - 2024.

75 f.

Coorientador(a) 1: Francisco Leite de Albuquerque Neto.

Orientador(a): Denisson Queiroz Oliveira.

Dissertação (Mestrado) - Programa de Pós-graduação em Engenharia Elétrica/ccet, Universidade Federal do Maranhão, São Luiz, 2024.

1. Energia eólica. 2. LIDAR. 3. Previsão da Velocidade do Vento. 4. Previsão de rampas. 5. Random Forests. I. Neto, Francisco Leite de Albuquerque. II. Oliveira, Denisson Queiroz. III. Título.

Josélio da Conceição Cruz

Proposta de um Modelo Preditivo para Eventos de Rampa de Vento Utilizando *Random Forests*

Dissertação submetida à Coordenação do Curso de Pós-Graduação em Engenharia de Eletricidade da UFMA como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica na área de concentração de Sistemas de Energia.

São Luís-MA, 05 de março de 2024

Prof. Dr. Denisson Queiroz Oliveira

Orientador

Universidade Federal do Maranhão

Prof. Dr. Francisco Leite de Albuquerque

Neto

Coorientador

Universidade Federal do Rio de Janeiro

Prof. Dr. Shigeaki Leite de Lima

Examinador Interno

Universidade Federal do Maranhão

Prof. Dr. Vinícius Albuquerque de Almeida

Examinador Externo

Universidade Federal do Rio de Janeiro

São Luís

2024

Dedico este trabalho aos meus irmãos, José Núbio da Conceição Cruz e José Francisco da Conceição Cruz, que sempre estarão presentes em minha memória e em meu coração.

Agradecimentos

Agradeço, primeiramente, a Deus, meu Senhor e Rei, por me dar saúde e disposição todos os dias, permitindo-me, apesar de todas as dificuldades, concluir este trabalho.

Agradeço a toda a minha família, especialmente minha mãe, Maria Salete; meu pai, Manoel da Cruz; minha amada esposa, Lidianne Veras; e minha filha, Julia Catarina. Agradeço também pela amizade e pelo estímulo em seguir meus sonhos.

Agradeço ao meu orientador, professor Dr. Denisson Queiroz Oliveira, e ao meu coorientador, Dr. Francisco Leite de Albuquerque Neto, pela prontidão, pelas orientações impecáveis e pelos conhecimentos compartilhados.

A minha amiga, Leiliane Trindade, agradeço pelas incontáveis discussões que tanto enriqueceram este trabalho.

À Equatorial Energia e à Gera Maranhão, expresso minha gratidão pelo suporte financeiro e pela cessão de dados, essenciais para a realização desta pesquisa, por meio do Programa de P&D da ANEEL.

À CAPES, ao CNPq e à FAPEMA, agradeço pelo suporte financeiro.

*"Confia no Senhor de todo o teu coração, e não te estribes no
teu próprio entendimento."*

Provérbios 3:5

Resumo

O investimento global em energia eólica cresce impulsionado pelo potencial como fonte limpa e renovável, enfrentando o desafio da volatilidade inerente à produção eólica, especialmente em relação aos eventos de rampa de vento. Essas mudanças abruptas na velocidade do vento representam preocupações significativas para a estabilidade e eficiência dos sistemas de energia eólica, redes elétricas e mercados de eletricidade. A dissertação foca na previsão de eventos de rampa de vento, sublinhando a importância de aprimorar a estabilidade e eficiência dos sistemas de energia eólica diante da produção volátil. O objetivo principal é desenvolver e validar um modelo preditivo, especificamente o *Random Forests*, para antecipar esses eventos, utilizando dados obtidos por perfiladores de vento LIDAR. Esta estratégia visa atenuar os desafios trazidos pela variabilidade da geração eólica, afetando tanto as redes elétricas quanto o mercado de eletricidade. A metodologia incorpora a coleta e validação de dados do vento, empregando o *Random Forests* para análise e categorização dos eventos, complementada por uma análise de sensibilidade para testar a eficácia do modelo. A escolha das *Random Forests* se justifica por sua combinação única de simplicidade, robustez e desempenho. Ao combinar várias árvores de decisão, as *Random Forests* mitigam o risco de *overfitting*. Cada árvore é treinada em um subconjunto aleatório dos dados, evitando que o modelo se torne excessivamente específico para o conjunto de treinamento. A análise de sensibilidade confirma a capacidade do modelo de gerenciar a complexidade e variabilidade dos dados de vento, ressaltando sua utilidade na melhoria da previsão e gestão da energia eólica. Conclui-se que a modelagem preditiva, através do *Random Forests*, é uma contribuição valiosa para o setor de energia eólica, possibilitando uma integração mais segura e eficiente nas matrizes energéticas. A implementação desses modelos preditivos é reconhecida como um avanço essencial para lidar com a volatilidade da produção eólica, fomentando a sustentabilidade e a segurança energética.

Palavras-chave: Energia Eólica; Rampas Eólica; Matriz Energética; Sistema de Energia; Energias Limpas, Árvores de Decisão, *Random Forests*.

Abstract

Global investment in wind energy is growing, driven by its potential as a clean and renewable source, while facing the challenge of inherent volatility in wind production, especially concerning wind ramp events. These abrupt changes in wind speed pose significant concerns for the stability and efficiency of wind energy systems, electrical grids, and electricity markets. The dissertation focuses on predicting wind ramp events, underscoring the importance of enhancing the stability and efficiency of wind energy systems amidst volatile production. The main objective is to develop and validate a predictive model, specifically Random Forests, to anticipate these events, utilizing data obtained from LIDAR wind profilers. This strategy aims to mitigate challenges brought by wind generation variability, affecting both electrical grids and the electricity market. The methodology incorporates wind data collection and validation, employing Random Forests for event analysis and categorization, complemented by sensitivity analysis to test the model's effectiveness. The choice of Random Forests is justified by their unique combination of simplicity, robustness, and performance. By combining multiple decision trees, Random Forests mitigate the risk of overfitting. Each tree is trained on a random subset of the data, preventing the model from becoming overly specific to the training set. Sensitivity analysis confirms the model's ability to manage the complexity and variability of wind data, highlighting its utility in improving wind energy prediction and management. It is concluded that predictive modeling through Random Forests is a valuable contribution to the wind energy sector, enabling safer and more efficient integration into energy matrices. The implementation of these predictive models is recognized as an essential advancement in dealing with wind production volatility, fostering sustainability and energy security.

Keywords: Wind Energy; Wind Ramps; Energy Matrix; Energy System; Clean Energy; Decision Trees; Random Forests.

Lista de Figuras

Figura 1 – Representação visual da árvore de decisão.	23
Figura 2 – Modelo genérico de uma <i>Random Forests</i>	25
Figura 3 – O sensor remoto <i>WINDCUBE</i> na região de estudo.	30
Figura 4 – Esquema genérico de um sistema LIDAR	31
Figura 5 – Pluviômetro de báscula	31
Figura 6 – Mapa dos pontos de medição na área de estudo em Paulino Neves-MA, Brasil.	33
Figura 7 – Conjuntos de treinamento usando validação cruzada com <i>k-folds</i>	34
Figura 8 – Fluxograma da metodologia proposta.	36
Figura 9 – Estimativa do vento em 60 minutos no ponto P0.	38
Figura 10 – Estimativa do vento em 60 minutos no ponto P1.	42
Figura 11 – Estimativas do vento em 60 minutos no ponto P6.	45
Figura 12 – Estimativas do vento em 60 minutos nos pontos P2 e P7.	47

Lista de tabelas

Tabela 1 – Localização dos Pontos de Medição e Proximidade à Costa	32
Tabela 2 – Tabela de localização, período e quantidade de observações válidas. . .	32
Tabela 3 – Desempenho do Modelo em Diferentes Alturas e Tempos no ponto P0 .	39
Tabela 4 – Métrica Classificação para o ponto P0	40
Tabela 5 – Matriz de confusão para o ponto P0	41
Tabela 6 – Métrica de regressão em Diferentes Alturas e Tempos no ponto P1 . . .	42
Tabela 7 – Métrica Classificação (F1 Score e Acurácia) para o ponto P1	43
Tabela 8 – Tabela de Matriz de confusão para o ponto P1	44
Tabela 9 – Desempenho do Modelo em Diferentes Alturas e Tempos no ponto P6 .	45
Tabela 10 – Métrica Classificação para o ponto P6	46
Tabela 11 – Matriz de confusão para o ponto P6	46
Tabela 12 – Comparação do Desempenho dos Modelos nos Pontos P2 e P7 em Diferentes Alturas e Tempos	48
Tabela 13 – Métricas Classificação nos Pontos P2 e P7 em Diferentes Alturas e Tempos	49
Tabela 14 – Tabela de Matriz de confusão nos Pontos P2 e P7 em Diferentes Alturas e Tempos	50
Tabela 15 – Métricas de regressão para diferentes alturas e tempo no ponto P0 . . .	60
Tabela 16 – Métricas de regressão para diferentes alturas e tempo no ponto P1 . . .	61
Tabela 17 – Métricas de regressão para diferentes alturas e tempo no ponto P2 . . .	62
Tabela 18 – Métricas de regressão para diferentes alturas e tempo no ponto P6 . . .	63
Tabela 19 – Métricas de regressão para diferentes alturas e tempo no ponto P7 . . .	64
Tabela 20 – Métricas de classificação em diferentes alturas e tempo no ponto P0 . .	66
Tabela 21 – Métricas de classificação em diferentes alturas e tempo no ponto P1 . .	67
Tabela 22 – Métricas de classificação em diferentes alturas e tempo no ponto P2 . .	68
Tabela 23 – Métricas de classificação em diferentes alturas e tempo no ponto P6 . .	69
Tabela 24 – Métricas de classificação em diferentes alturas e tempo no ponto P7 . .	70
Tabela 25 – Matriz de confusão para diferentes alturas e tempos no ponto P0.	72
Tabela 26 – Matriz de confusão para diferentes alturas e tempos no ponto P1.	73
Tabela 27 – Matriz de confusão para diferentes alturas e tempos no ponto P2.	74
Tabela 28 – Matriz de confusão para diferentes alturas e tempos no ponto P6.	75
Tabela 29 – Matriz de confusão para diferentes alturas e tempos no ponto P7.	76

Lista de abreviaturas e siglas

GW	<i>Gigawatt</i>
MW	<i>Megawatt</i>
ONS	Operador Nacional do Sistema Elétrico
RAP	Relatório de Análise de Perturbação
ODS	Objetivos do Desenvolvimento Sustentável
ONU	Organização das Nações Unidas
SE	Sistemas Elétricos
MSAR	<i>Markov-Switching-Auto-Regression</i>
GPR	Regressão do Processo Gaussiano
RMSE	<i>Root Mean Square Error</i>
MAE	<i>Mean Absolute Error</i>
MLP	Perceptron Multicamadas
MCS	Sistemas Convectivos de Mesoescala
NAM	Mesoescala Norte Americano
MAPE	<i>Mean Absolute Percentage Error</i>
NWP	<i>Numerical Weather Prediction</i>
R ²	Coeficiente de Determinação
LIDAR	<i>Light Detection and Ranging</i>
RF	<i>Random Forests</i>
SODAR	<i>Sound Detection And Ranging</i>
VP	Verdadeiros Positivos
FP	Falsos Positivos
FN	Falsos Negativo
VN	Verdadeiros Negativos

F1SC	<i>F1-Score</i> Crescente
F1SD	<i>F1-Score</i> Decrescente
Qtd	Quantidade
Obs	Observações
CNN	Rede Neural Convolucional
OpSDA	Algoritmo de porta oscilante otimizado
LSTM	Memória de longo prazo
CNN-LSTM	Rede Neural Convolucional - Memória de Longo Prazo
ZCIT	Zona de Convergência Intertropical

Sumário

1	INTRODUÇÃO	15
1.1	Justificativa	16
1.2	Objetivo Geral e Específicos	17
1.3	Estado da arte	17
1.4	Organização do Trabalho	20
2	FUNDAMENTAÇÃO TEÓRICA	21
2.1	Rampas de vento	21
2.2	Árvores de Decisão	22
2.3	<i>Random Forests</i>	24
2.4	Métricas de Avaliação	25
2.4.1	<i>Root Mean Square Error (RMSE)</i>	25
2.4.2	Coeficiente de Determinação (R^2)	26
2.4.3	<i>Mean Absolute Percentage Error (MAPE)</i>	26
2.4.4	Matriz de Confusão	27
2.4.5	Acurácia	27
2.4.6	<i>Recall</i>	27
2.4.7	<i>Precision</i>	28
2.4.8	<i>F1-Score</i>	28
3	METODOLOGIA	29
3.1	Características do Local de Estudo	29
3.2	Sensores	30
3.3	Dados	31
3.4	Desenvolvimento do modelo	33
4	RESULTADOS	37
4.1	Resultados e análises para o ponto P0	38
4.2	Resultados e análises para o ponto P1	41
4.3	Resultados e análises para o ponto P6	44
4.4	Resultados e análises para o ponto P2 e P7	46
5	CONCLUSÃO	51
5.1	Trabalhos Futuros	51
5.2	Artigos Publicados	52

Referências	53
-----------------------	----

APÊNDICES	58
------------------	-----------

APÊNDICE A – TABELAS DE MÉTRICAS DE REGRESSÃO.	59
--	----

APÊNDICE B – TABELAS DE MÉTRICAS DE CLASSIFICAÇÃO.	65
--	----

APÊNDICE C – MATRIZ DE CONFUSÃO EM DIFERENTES ALTURA E HORIZONTES DE TEMPO	71
---	----

1 Introdução

No contexto atual, as questões ambientais e a necessidade de reduzir as emissões de gases de efeito estufa na atmosfera ganham espaço nas discussões sobre transição energética. Desse modo, as energias renováveis, como a energia eólica, assumem um papel relevante na transição para uma economia de baixo carbono.

A matriz energética global é predominantemente baseada em fontes poluentes, com as energias renováveis contribuindo com aproximadamente 15%. No entanto, o Brasil se destaca por sua matriz energética mais sustentável, onde 47,4% da energia provém de fontes renováveis. Quando olhamos especificamente para a matriz elétrica, a diferença se torna ainda mais evidente. Enquanto a matriz elétrica mundial ainda depende fortemente de fontes não renováveis, o Brasil apresenta uma matriz elétrica com 84,8% de sua energia gerada por fontes renováveis, em comparação com apenas 28,1% no cenário global. Essa característica coloca o Brasil em uma posição de liderança na transição para uma energia mais limpa e menos poluente. Nesse contexto, em relação à geração de energia elétrica, a fonte eólica correspondeu a 11,8% da matriz elétrica brasileira em 2022 [1]. O crescimento da capacidade instalada das usinas eólicas no país foi significativo nos últimos 10 anos, passando de 2.202 MW, em 2013, para 23.761 MW, em 2022. A geração elétrica por meio de fonte eólica foi ainda mais substancial nesse mesmo período, saltando de 6.578 GWh para 81.632 GWh [2].

A energia eólica é uma fonte de energia considerada limpa, renovável e inesgotável, não emissora de poluentes atmosféricos e nem de gases do efeito estufa, contribuindo para a minimização das mudanças climáticas. Ela também promove a diversificação da matriz energética, diminuindo a dependência de combustíveis fósseis e traz mais segurança energética, a qual é um dos pilares da Política Energética Nacional - Lei nº 9.478/1997 [3]. Também é preciso considerar que a produção de energia acessível e limpa é um dos Objetivos do Desenvolvimento Sustentável (ODS) da Agenda 2030, proposta pela Organização das Nações Unidas (ONU), sendo um vetor importante para o alcance dos demais objetivos[4].

Apesar disso, a expansão da energia eólica não está isenta de desafios que dificultam a exploração dos potenciais benefícios dessa fonte. Os autores em [5] apontam pelo menos 24 barreiras para a ampliação do uso da energia eólica relacionadas às dinâmicas de mercado, financeiras, institucionais, sociais e técnicas. Dentre as barreiras de ordem técnica, tem-se a intermitência da velocidade do vento, que pode ocasionar picos e quedas na produção de energia e necessidade de mobilizar fontes alternativas para compensação, dificultando a incorporação dessa fonte ao sistema elétrico. [6] Essas

grandes variações na velocidade do vento podem causar rampas de energia eólica e por em risco a operação do sistema de potência [7].

Os eventos de rampa eólica podem causar transtornos ao Operador Nacional do Sistema Elétrico (ONS). Situação recente envolvendo a ocorrência de rampas contribuiu para um blecaute registrado em 15 de agosto de 2023. Conforme apontado na minuta do Relatório de Análise de Perturbação (RAP), os equipamentos de controle de parques eólicos e fotovoltaicos tiveram um mau desempenho. Devido ao aumento no fluxo de potência na rede, uma linha de transmissão desligou, mas o religamento automático desta apresentou falhas. Foi constatada a interrupção de 23.368 MW, do total de 67.507 MW, ou seja, 27% do consumo de energia elétrica do Brasil. O RAP propõe medidas a serem implementadas pelos agentes e geradores eólicos e fotovoltaicos, entre as quais destaca-se a validação dos modelos preditivos [8].

Em vista disso, o desenvolvimento de modelos preditivos para eventos de rampa em centrais eólicas é relevante na gestão e integração da energia eólica na matriz energética [9]. A quantificação das rampas é uma necessidade para a tomada de decisões e continuidade da operação da rede elétrica [10].

1.1 Justificativa

A realização desta pesquisa justifica-se em razão da importância da fonte eólica diante das discussões sobre desenvolvimento sustentável, ao nível global e principalmente no contexto nacional, tendo em vista o crescimento da inserção desse tipo de energia no Sistema Elétrico brasileiro.

A energia eólica é essencial para o desenvolvimento sustentável e tem crescido no sistema elétrico brasileiro. Contudo, alguns desafios precisam ser superados para uso efetivo da fonte eólica. Dentre eles destaca-se a sujeição às condições do vento, as quais são naturalmente voláteis. Nesse sentido, essas variações repentinas da velocidade do vento, denominadas de eventos de rampa, podem impactar na produção de energia nas centrais eólicas, colocando em risco a segurança, qualidade e confiabilidade do Sistema Elétrico. Os eventos de rampa eólica podem ainda causar instabilidade da rede elétrica, e com isso, desequilibrar a relação oferta e demanda, levando à quedas de energia, sobretensões e outros eventos adversos.

O desenvolvimento de modelos preditivos é essencial para a redução desses efeitos e para aperfeiçoar o planejamento e a operação eficiente do sistema elétrico. Os modelos de previsão podem também trazer benefícios ambientais ao permitir a integração de mais energia limpa na rede elétrica, favorecendo a sustentabilidade ambiental. Os efeitos das previsões estendem-se ainda ao aspecto econômico, visto que minimizam os custos associados aos problemas provocados pela ocorrência dos eventos de rampa.

1.2 Objetivo Geral e Específicos

O objetivo principal desta pesquisa é desenvolver um modelo capaz de prever a velocidade do vento em um horizonte de curto prazo para classificar rampas de vento. Este estudo busca contribuir significativamente para a operação e gestão de Sistemas Elétricos (SE), melhorando a compreensão e a resposta aos eventos de rampa eólica.

Os objetivos específicos propostos são:

- Desenvolver previsão do perfil vertical do vento, visando a quantificação e avaliação da variabilidade temporal do vento;
- Analisar a influência da altura na percepção de variações de vento.
- Determinar a eficiência do modelo de previsão em diferentes alturas e horizontes temporais, por meio da análise dos dados de regressão e classificação.

1.3 Estado da arte

A estimativa da geração de energia a partir dos ventos se apresenta como uma tarefa complexa, dada a natureza variável do vento. Influenciada por diferentes elementos - condições climáticas, características geográficas e variações sazonais - a previsão da velocidade do vento se torna um exercício complexo. Essa decisão nas soluções é vital para otimizar a operação de parques eólicos, facilitando um planejamento energético mais eficaz e reduzindo a dependência de fontes energéticas fósseis, o que traz benefícios tanto em termos de eficiência técnica quanto econômica [11]

O aumento da utilização da energia eólica acarreta a inserção de elementos de incerteza nos sistemas de energia, conferindo maior complexidade à operação em tempo real. Diversas estratégias têm sido implementadas com o intuito de aprimorar a eficiência operacional dos sistemas de energia na integração da energia eólica [12]. Nessa ótica, a previsão de eventos de variação abrupta na produção de energia eólica assume um papel fundamental na segurança da rede elétrica e na eficaz otimização da gestão energética. As capacidades operacionais em tempo real desempenham um papel vital na resposta imediata a ocorrências de rampas eólicas. Os modelos preditivos devem demonstrar competência na análise de dados em tempo real, capacitando-se a efetuar projeções que acionem medidas adequadas para atenuar os efeitos adversos ocasionados por esses eventos [13].

Os eventos de rampa de energia eólica são influenciados por variações sazonais na velocidade do vento, resultantes de diversos fatores, desde padrões climáticos em grande escala até efeitos locais. Regiões com flutuações diárias mais pronunciadas na velocidade do vento e ventos alísios, principalmente no verão, apresentam maior frequência de rampas de energia eólica, o que aumenta a produção energética. Sistemas frontais e sistemas

convectivos de mesoescala (MCS) são reconhecidos como principais impulsionadores de eventos persistentes de alta geração. Esses eventos são mais frequentes em áreas influenciadas por ventos alísios e passagens frontais. Contudo, modelos de previsão, como o Sistema de previsão de mesoescala norte-americano (NAM) e o Modelo de Atualização Rápida (RAP), possuem limitações na previsão da variabilidade do vento em terrenos complexos, pois subestimam ventos fortes e superestimam ventos fracos, resultando em subestimações de eventos de alta e baixa geração de energia eólica [14].

Um estudo realizado por [15] empregou técnicas de análise de séries temporais e modelos híbridos para prever a média mensal da velocidade do vento em locais como Fortaleza-CE, Parnaíba-PI, São Luis-MA e Natal-RN, registrando taxas de erro de 3,80%, 3,85%, 4,91% e 2,85%, respectivamente.

Em contrapartida, [16] levantou uma crítica contra os modelos físicos, como a previsão numérica do tempo (NWP), e abordagens estatísticas reveladas, como o modelo Autoregressivo (AR) e o ARIMA, apontando suas limitações em contextos não-lineares. Uma análise comparativa feita por [17] destacou o potencial das Redes Neurais Artificiais como ferramenta preditiva, ressaltando que a sinergia entre diferentes modelos pode diminuir notavelmente os erros de previsão. Um método que exemplifica essa abordagem é o *Ensemble*, que integra dados de múltiplas fontes.

Random forests são *ensembles* de árvores de decisão construídas utilizando sub-amostras dos dados e das variáveis explicativas. Tal característica reside na capacidade de combinar um grande número de árvores de decisão, com diferentes respostas, em um único resultado. As árvores de decisão, além de serem úteis em aplicações de regressão, mostram-se versáteis em uma variedade de aplicações, desde variações de vendas e preços até estimativas de demanda, minimizando erros e oferecendo uma boa adaptabilidade. [18].

Em relação aos eventos de rampa eólica, eles são definidos como flutuações súbitas dos ventos, podendo ter características de subida e/ou descida na produção de energia eólica e interromper as operações do fornecimento de eletricidade. As rampas possuem magnitude, duração, direção, e *timing*. Assim, um evento de rampa pode ocorrer caso um ou mais limiares desses aspectos sejam ultrapassados [19].

Existe uma relação clara entre três fatores de eventos de rampa de energia eólica - sua amplitude, duração e horário de início - e o impacto que eles têm na geração de energia eólica. Primeiramente, a amplitude das rampas, que se refere à variação na disponibilidade de energia eólica, influencia diretamente a estabilidade da geração: amplitudes maiores podem levar a desequilíbrios mais significativos na potência. Contudo, quando as amplitudes são inferiores a 30% da capacidade total instalada, o impacto é geralmente menor. Além disso, a duração destas rampas determina a velocidade com que as mudanças ocorrem, podendo em alguns casos exceder a capacidade de reserva do sistema. Por fim, o horário em que as rampas começam afeta a taxa de variação da carga líquida do sistema, podendo

causar ou mitigar desequilíbrios. Por isso, é essencial ter previsões precisas desses eventos para gerenciar e controlar efetivamente o sistema de energia, especialmente em face de variações imprevisíveis. [20].

As regulação primária devida à ocorrência de rampas atualmente são realizadas por meio de unidades convencionais, o que torna o processo mais caro e o sistema menos eficiente. O controle coordenado entre parques eólicos é uma alternativa para minimização desses impactos. As diferenças na produção de energia, em razão da distribuição dos parques eólicos em uma ampla área, podem ser empregadas para o controle coordenado desses parques. A distribuição geográfica reduz os erros de previsão de energia eólica, contribuindo para um planejamento mais fácil e razoável do sistema. O desenvolvimento de pesquisas envolvendo esse tema é uma necessidade emergente [21] [22] [23].

De acordo com [24], os métodos de previsão de rampas eólicas ainda possuem imperfeições, pois harmonizam as tendências de longo prazo e precisão de curto prazo. Com base nisso, esses autores desenvolveram um método avançado que utiliza a curva de energia eólica para construir um modelo primário, cujos resíduos foram corrigidos por um modelo *Markov-Switching-Auto-Regression* (MSAR), seguido da aplicação de algoritmo aprimorado para extrair segmentos lineares. Os resultados demonstraram que o modelo ARMA superou o modelo primário, e a abordagem baseada no modelo MSAR forneceu o melhor desempenho de previsão de rampa.

Eventos de rampa podem ser previstos a partir de uma ótica especificamente estatística, utilizando dados históricos da série de potência, por meio de uma abordagem físico-numérica, por exemplo, modelos de NWP, ou combinando-se as duas abordagens. O autor de [25] desenvolveu modelos de previsão de rampas, a curtíssimo prazo, baseados em séries temporais. Com uso de redes neurais do tipo *perceptron* multicamadas (NN-MLP) e modelos de redes *bayesianas*, foi possível obter resultados satisfatórios para as rampas de subida, mas para rampas de descida o estudo encontrou dificuldades em prevê-las.

Redes Neurais profundas para a previsão de eventos de rampa apresentam bom desempenho. Na proposta de [26], o modelo utilizando essa abordagem foi capaz de prever tanto os eventos de rampa quanto a magnitude desses, mostrando-se uma ferramenta promissora para a integração da energia eólica na rede elétrica. [27] propuseram um método de classificação baseado em árvores de decisão aprimoradas (GBRT). O modelo GBRT foi o melhor preditor de eventos de rampa de vento, segundo uma comparação de vários modelos de aprendizagem de máquina, obtendo a maior pontuação F1 geral e precisão para eventos de rampa raros em dois conjuntos de dados diferentes.

Os autores de [28] aplicaram a técnica de Regressão do Processo Gaussiano (GPR) e dados de reanálise atmosférica para previsão de rampas eólicas. O estudo encontrou um bom desempenho para o Erro Quadrático Médio (RMSE), Erro Médio Absoluto (MAE) e sensibilidade, ainda que alguns regressores tenham tido melhor desempenho em relação a

outros. O modelo GPR obteve os melhores resultados entre todos os regressores testados, com uma excelente saída da função de rampa $S1t$ a partir das variáveis *ERA-Interim*. O pior resultado encontrado no modelo corresponde ao *Perceptron* Multicamadas (MLP), cuja detecção foi mais fraca para rampas positivas comparado a outros regressores.

Os autores de [29] realizaram a previsão de eventos de rampa eólica com base em aprendizado profundo. Inicialmente, os pesquisadores fizeram a detecção de dados históricos de energia eólica usando o algoritmo de porta oscilante otimizado (OpSDA). Depois, um modelo de previsão Rede Neural Convolucional - Memória de Longo Prazo (CNN-LSTM) foi estabelecido. O modelo de aprendizagem profunda, que combina CNN para extração de recursos e LSTM para previsão de sequência, foi usado para explorar a relação de acoplamento entre os recursos de rampa identificados e a geração de energia eólica. Após treinar o modelo CNN-LSTM, fez-se a previsão dos eventos de rampa eólica, nos quais os valores de potência previstos foram obtidos através da redetecção da potência prevista. Os resultados apontaram para a conformidade do modelo CNN-LSTM, que obteve uma alta taxa média anual de *recall* de 0,9059.

A Regressão Logística Multinomial, usada quando a variável de resultado possui mais de duas categorias, também apresenta bons resultados quando empregada para prever os níveis ordinais da rampa de energia eólica. No estudo de [30], os autores propuseram modelos de regressão logística separados usando dados de diferentes sites do *Mesonet*. para desenvolver um modelo individual de previsão dos níveis de rampa de energia eólica. Em vez de combinar os dados de diferentes locais, a abordagem combinou resultados das previsões de modelos individuais, que foram desenvolvidos de forma independente e suas previsões comparadas para produzir uma previsão final.

1.4 Organização do Trabalho

Além desta introdução, o trabalho divide-se em mais três capítulos. O primeiro capítulo apresenta a fundamentação teórica, onde o conceito de rampa é definido, bem como as árvores de decisão, *random forest* e algumas das métricas de avaliação mais empregadas.

O segundo capítulo detalha o percurso metodológico utilizado na pesquisa, descrevendo as etapas de desenvolvimento do modelo, a coleta de dados, a validação e análise de sensibilidade.

O terceiro capítulo abrange os resultados obtidos e discussões dos mesmo.

Por fim, a última parte do trabalho contempla as considerações finais sobre os resultados desta dissertação e abre espaço para pesquisas futuras sobre o tema.

2 Fundamentação Teórica

Este capítulo abrange as definições e métricas relacionadas aos eventos de rampa de vento e técnicas de modelagem preditiva, com foco em árvores de decisão e *Random Forests*. Além disso, discutem-se métricas de avaliação comuns para previsão e classificação, como RMSE, R^2 , MAPE, Matriz de Confusão, Acurácia, *Precision*, *Recall* e *F1-Score*, que serão utilizadas para avaliar o desempenho dos modelos desenvolvidos neste estudo.

2.1 Rampas de vento

As rampas de ventos são definidas como mudanças relativamente grandes na velocidade do vento durante um curto período de tempo. Essas rampas apresentam desafios para as concessionárias de energia elétrica no equilíbrio entre geração e carga de energia[31]. O conceito de rampas eólicas é particularmente relevante no contexto da geração de energia eólica, onde mudanças repentinas na velocidade do vento podem levar a flutuações significativas na produção de energia.

Conforme observado em [25], não se encontra na literatura uma definição universal para eventos de rampas. No entanto, é comum observar que as rampas são frequentemente definidas de acordo com as diretrizes propostas por [32].

- **Magnitude (Δy):** Esta medida quantifica a mudança relativa na potência durante a ocorrência da rampa.
- **Duração (Δt):** Este parâmetro indica o período de tempo em que a rampa é observada.
- **Direção:** Este critério determina se a rampa representa um aumento (rampa de subida) ou uma diminuição (rampa de descida) na potência.
- **Timing(t_0):** Este valor especifica o momento relativo em que a rampa ocorre.

Em [33] os autores exploram diversas definições de eventos de rampa de vento. Esses eventos são cruciais para entender a variabilidade na produção de energia eólica e suas implicações na operação do sistema de energia. As definições são apresentadas da seguinte forma:

1. **Definição 1:** Um evento de rampa é identificado quando a magnitude da variação no sinal de potência dentro de um intervalo Δt supera um valor de limiar predefinido P_{val} .

Matematicamente, isso é expresso como:

$$P(t + \Delta t) - P(t) > P_{val} \quad (2.1)$$

Esta formulação foca na variação absoluta da potência em um intervalo específico.

2. **Definição 2:** Nesta definição, um evento de rampa ocorre quando a diferença entre a potência máxima e mínima medida nesse intervalo Δt excede um valor de limiar P_{val} :

$$\max P[t, t + \Delta t] - \min P[t, t + \Delta t] > P_{val} \quad (2.2)$$

Esta abordagem considera os extremos da produção de energia no período estabelecido.

3. **Definição 3:** Aqui, um evento de rampa é identificado quando o valor absoluto do sinal filtrado pf_t no intervalo Δt ultrapassa um valor de limiar P_{val} .

O "sinal filtrado" pf_t refere-se a um sinal de potência processado para remover ruídos ou componentes irrelevantes, deixando apenas as variações significativas que são de interesse. Quando a magnitude dessa variação (sem considerar a direção, seja aumento ou diminuição) excede um valor de limiar específico P_{val} , é considerado que ocorreu um evento de rampa.

4. **Definição 4:** De acordo com esta definição, um evento de rampa ocorre quando a razão entre a diferença absoluta da potência no intervalo Δt é maior que um valor de referência predefinido PRP_{val} :

$$\frac{|P(t + \Delta t) - P(t)|}{\Delta t} > PRP_{val} \quad (2.3)$$


Este critério enfoca a taxa de variação da potência ao longo do tempo.

Os autores de [33] destacam que cada uma dessas definições enfoca diferentes aspectos dos eventos de rampa de vento e têm suas próprias vantagens e limitações. Essas definições ajudam a caracterizar eventos de rampa de forma mais precisa, o que é essencial para o desenvolvimento de estratégias eficazes de gerenciamento e previsão na produção de energia eólica.

2.2 Árvores de Decisão

As árvores de decisão representam uma técnica popular e robusta no campo da modelagem preditiva. Essas estruturas hierárquicas de decisão são amplamente utilizadas em diversas áreas, desde aprendizado de máquina até sistemas de apoio à decisão [34]. É ilustrado por meio da Figura 1, uma árvore de decisão é composta por nós que

Figura 1 – Representação visual da árvore de decisão.



Fonte: [35]

representam decisões ou testes em relação a variáveis, e as arestas entre esses nós indicam os resultados desses testes, levando a diferentes caminhos ao longo da árvore.

Uma das características distintivas das árvores de decisão é sua capacidade de representar de forma clara a interpretação intuitiva das relações complexas entre variáveis e resultados. Segundo [34], as árvores de decisão são um método versátil para a aproximação de funções complexas e para a modelagem de relações entre variáveis. Sua estrutura hierárquica facilita a decomposição de problemas complexos em decisões mais simples, tornando a interpretação dos modelos resultantes acessível mesmo para não especialistas.

As árvores de decisão são aplicadas em uma variedade de contextos, desde classificação até regressão. Elas são particularmente valiosas em situações onde é essencial compreender a lógica por trás das decisões do modelo. Por exemplo, em diagnósticos médicos, as árvores de decisão ajudam a explicar o raciocínio por trás de cada diagnóstico, o que é crucial para a confiança dos pacientes e profissionais de saúde. Em sistemas de recomendação, como os usados por plataformas de *streaming*, elas contribuem

para a personalização e precisão das sugestões feitas aos usuários. Além disso, na previsão de tendências de mercado, as árvores de decisão auxiliam na identificação de padrões e influências chave, facilitando decisões estratégicas de negócios.

Os autores em [36] destacam que, apesar de sua simplicidade aparente, as árvores de decisão podem se ajustar muito bem aos dados e capturar relações complexas. Esta adaptabilidade é um dos motivos pelos quais são frequentemente escolhidas em problemas do mundo real, onde as relações entre variáveis podem ser não lineares e desafiadoras para métodos mais tradicionais.

No entanto, as árvores de decisão não estão isentas de limitações. Uma das principais limitações é a tendência ao *overfitting*, especialmente em árvores muito profundas. Isso ocorre quando a árvore se ajusta excessivamente aos dados de treinamento, perdendo a capacidade de generalizar para novos dados. Para mitigar isso, técnicas como a poda da árvore são utilizadas, onde se remove os ramos que fornecem pouca contribuição para a precisão do modelo [37].

2.3 *Random Forests*

A metodologia do algoritmo do *Random Forests* (RF), ou floresta aleatória, é baseada em um conjunto de árvores de decisão. Desta forma, cada árvore de decisão é baseada em algum atributo de escolha e este atributo é determinado de forma aleatória e é ele quem determina a divisão de cada nó da árvore [38].


Breiman propôs as RF em 2001 como uma evolução das Árvores de Decisão. Em vez de depender de uma única árvore para previsões, a Floresta Aleatória cria uma coleção diversificada de árvores, cada uma treinada em uma amostra aleatória do conjunto de dados [34]. O algoritmo é aplicável a tarefas de classificação e regressão, utilizando a criação de múltiplas árvores de decisão. Ele agrega suas previsões para melhorar a precisão e mitigar o *overfitting*. Para tarefas de classificação, a classe final é determinada pelo voto majoritário entre as árvores, enquanto para tarefas de regressão, a média das previsões das árvores é frequentemente utilizada. A Figura 2 representa um modelo genérico de RF.

A aleatoriedade nas RF é implementada de duas maneiras principais: amostragem de observações e amostragem de características. A cada estágio de construção de uma árvore, uma amostra aleatória dos dados de treinamento é selecionada. Além disso, em cada nó de decisão, apenas um subconjunto aleatório das características é considerado para fazer a divisão.

Essa abordagem contribui para a diversidade entre as árvores, tornando o modelo mais robusto e menos propenso a *overfitting*. A aleatoriedade garante que cada árvore

tenha uma visão única dos dados, e a combinação de várias visões contribui para uma decisão mais precisa e estável.

Figura 2 – Modelo genérico de uma *Random Forests*.



Fonte: [17]

2.4 Métricas de Avaliação

2.4.1 Root Mean Square Error (RMSE)

De acordo com [39], o RMSE é uma medida de quão bem um modelo se ajusta aos dados observados e é amplamente utilizado na previsão numérica do tempo para avaliar o erro na velocidade do vento e outras variáveis meteorológicas [40]. Como o RMSE é a raiz quadrada das diferenças entre os valores previstos e observados, ele tende a maximizar erros grandes, o que pode ajudar a filtrar métodos com tais erros.

O RMSE é calculado conforme a equação:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.4)$$

Em que:

- n é o número de observações.
- y_i é o valor real da i -ésima observação.

- $\hat{y}_i$ é o valor previsto da i -ésima observação.

2.4.2 Coeficiente de Determinação (R^2)

O R^2 é uma métrica que indica a proporção da variância na variável dependente que é previsível a partir das variáveis independentes. Em outras palavras, ele fornece uma medida de quão bem as previsões futuras provavelmente se alinharão com os valores reais. Valores de R^2 próximos de 1 indicam um ajuste muito bom do modelo [41].

O coeficiente de determinação R^2 é calculado conforme a equação:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (2.5)$$

Em que:

- n : Número de observações.
- y_i : Valor real da i -ésima observação.
- $\hat{y}_i$: Valor previsto da i -ésima observação.
- $\bar{y}_i$: Média dos valores reais da variável dependente.

2.4.3 Mean Absolute Percentage Error (MAPE)

O MAPE é uma medida de precisão em um método de previsão. Ele calcula o erro absoluto médio como uma porcentagem do valor observado, oferecendo uma perspectiva da magnitude do erro em termos relativos. Esta métrica é particularmente útil quando se deseja compreender a precisão das previsões em um contexto percentual [42].

O erro percentual médio absoluto (MAPE) é calculado conforme a equação:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (2.6)$$

No qual:

- n : Número de observações.
- y_i : Valor real da i -ésima observação.
- $\hat{y}_i$: Valor previsto da i -ésima observação.

2.4.4 Matriz de Confusão

A Matriz de Confusão é uma ferramenta para a avaliação de desempenho em problemas de classificação. Consiste em uma tabela que permite a visualização do desempenho de um algoritmo, mostrando a frequência de cada classe prevista em comparação com as classes reais. As linhas representam as instâncias da classe prevista pelo modelo, enquanto as colunas representam as instâncias da classe real. Em um cenário de classificação binária, a matriz é composta por quatro elementos: Verdadeiros Positivos (VP), Falsos Positivos (FP), Verdadeiros Negativos (VN) e Falsos Negativos (FN) [43].

$$\text{Matriz de Confusão} = \begin{bmatrix} VP & FP \\ FN & VN \end{bmatrix} \quad (2.7)$$

A análise da Matriz de Confusão revela não apenas os erros cometidos pelo modelo, mas também o tipo de erros. Dependendo da aplicação falso negativo e falso positivo podem ter importância distinta. Assim, essa matriz se torna essencial para entender em que aspectos o modelo precisa ser melhorado [44].

2.4.5 Acurácia

A Acurácia é uma das métricas mais intuitivas para avaliar modelos de classificação. Ela é calculada como a proporção de previsões corretas (tanto positivas quanto negativas) em relação ao total de previsões feitas [45]. Matematicamente, é expressa como:

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} \quad (2.8)$$

Em que:

- VP é o número de verdadeiros positivos.
- VN é o número de verdadeiros negativos.
- FP é o número de falsos positivos.
- FN é o número de falsos negativos.

Embora a acurácia seja uma medida útil para ter uma visão geral do desempenho do modelo, ela pode ser enganosa em conjuntos de dados desequilibrados, onde uma classe é muito mais frequente do que as outras.

2.4.6 Recall

É a proporção de previsões corretas para uma categoria em relação ao total de elementos de uma categoria.

$$\text{Recall} = \frac{VP}{VP + FN} \quad (2.9)$$

onde verdadeiros positivos é o número de instâncias positivas classificadas corretamente pelo modelo, e falsos negativos é o número de instâncias positivas que o modelo classificou como negativas.

2.4.7 *Precision*

É a proporção de previsões corretas para uma categoria em relação ao total de previsões para uma categoria.

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (2.10)$$

No qual verdadeiros positivos é o número de instâncias positivas classificadas corretamente pelo modelo, e falsos positivos é o número de instâncias negativas que o modelo classificou como positivas.

2.4.8 *F1-Score*

O *F1-Score* é uma métrica que combina *Precisão* e *Recall* em uma única medida, oferecendo um balanço entre essas duas métricas. A *Precisão* é a proporção de identificações positivas que foram realmente corretas, enquanto o *Recall* é a proporção de casos positivos reais que foram identificados corretamente [46]. O *F1-Score* é particularmente útil ao se precisar de um equilíbrio entre *Precisão* e *Recall* e há uma distribuição desigual de classes. É calculado pela fórmula:

$$F1 = 2 \times \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \quad (2.11)$$

3 Metodologia

Esta seção apresenta a descrição detalhada da área de estudo, do sensor, da coleta e filtragem dos dados, bem como do desenvolvimento do modelo preditivo em questão utilizando o algoritmo de *Random Forest*. Os dados do estudo têm como base o período de novembro de 2021 a novembro de 2022, obtidos no âmbito do projeto EOSOLAR e referem-se ao município de Paulino Neves, estado do Maranhão, Brasil. Esse local foi escolhido em razão das características geográficas que possibilitam a geração eólica.

3.1 Características do Local de Estudo

Paulino Neves é um município brasileiro localizado na Mesorregião Norte do estado do Maranhão e na Microrregião dos Lençóis maranhenses. Possui uma área territorial de 979,482 km², população de 17.056 pessoas e densidade demográfica de 17,41 habitantes por quilômetro quadrado [47]. Esse município é limítrofe, ao norte, com o Oceano Atlântico; ao sul, com o município de Santana do Maranhão e Tutóia; a leste com o município de Tutóia; e a oeste, com o município de Barreirinhas.

O município de Paulino Neves está a uma altitude de 4 metros acima do nível do mar e apresenta variação térmica de 22,8°C e 31,3°C. Possui clima sub úmido; com um período chuvoso (de janeiro a junho) e outro período seco (de julho a dezembro). Além disso, a topografia da área é caracterizada por uma planície litorânea moldada pela ação de forças oceânicas, especialmente próximas à costa de suave ondulação, onde predominam vastas regiões baixas de origem sedimentar recente. Nesta região litorânea, destacam-se dunas móveis variadas em tipos e dimensões, alcançando até 30 metros de altura. Estas dunas progridem em direção ao interior, sobrepondo-se à vegetação do Cerrado local. A área faz parte da Bacia hidrográfica secundária dos Rios Convergentes do litoral Oriental. A vegetação é diversificada, influenciada por fatores marinhos e fluviais, incluindo Cerrado e florestas estacionais [48].

A região de estudo é propícia à geração de energia eólica, e os dois principais fenômenos que governam esse potencial são os ventos alísios e a brisa marítima-terrestre. Os ventos alísios são formados pelo deslocamento de massas de alta pressão das regiões subtropicais para a região equatorial de baixa pressão e, influenciados pela força de Coriolis, tomam a direção predominante de leste-sudeste. Esses ventos são estáveis e têm maior velocidade em regiões de pouca rugosidade, como a superfície dos oceanos. As brisas marítima e terrestre são formadas pela diferença de pressão entre o continente e o oceano, em função da variação distinta de temperatura entre essas duas superfícies. A primeira, muito mais intensa, acontece durante o dia, e a segunda, por vezes inexistente, ocorre após

o resfriamento da superfície do continente no período noturno. A combinação dos alísios com a brisa marítima e terrestre define a direção do vento nesta região.[49]

Devido às características geográficas e estratégicas, Paulino Neves se destaca pelo potencial eólico, possuindo um complexo eólico com capacidade instalada de 220,8 megawatts, abrangendo uma extensão de 2.368,9 hectares [50].


3.2 Sensores

Para a realização deste trabalho, foram coletados dados com o uso do *WindCube*, um perfilador de vento que opera com a tecnologia LIDAR (*Light Detection and Ranging*) de efeito Doppler. Este equipamento, ilustrado na figura 3, emprega pulsos de laser na banda infravermelha (1543 nm) para estimar a velocidade e a direção do vento. Os pulsos laser são refletidos por aerossóis e partículas atmosféricas, como poeira e gotículas de água, e a energia retroespalhada é capturada pelo sistema para análise ilustrado na figura 4. O cálculo do desvio Doppler, resultante da mudança na frequência da onda refletida pelas partículas em movimento, permite uma estimativa da velocidade radial do vento [51].

Figura 3 – O sensor remoto *WINDCUBE* na região de estudo.



Figura 4 – Esquema genérico de um sistema LIDAR



Fonte: [52]

Além disso, o *WindCube* tem a capacidade de medir a velocidade do vento em até 20 diferentes alturas de 40 a 300 metros, permitindo a caracterização do perfil vertical do vento nas alturas das turbinas eólicas modernas. Essas informações aumentam a eficiência da estimativa de geração de energia eólica [51].

O estudo também incorporou o uso do pluviômetro TE525-L da *Campbell Scientific*, conforme ilustrado na Figura 5. Este sensor foi empregado para registrar a quantidade de precipitação em cada local de medição. Caracteriza-se por uma precisão de $\pm 1\%$ para índices pluviométricos de até 50 mm/h. Apesar de sua simplicidade, o TE525 demonstra ser um instrumento notavelmente eficiente para o monitoramento de chuvas em diversos ambientes.

Figura 5 – Pluviômetro de báscula



Fonte: [53]

3.3 Dados

Utilizando o sensor LIDAR, foram obtidos dados de medição de 40m a 260m de altura em intervalos de 10 minutos, em diversos pontos, denominados de P0, P1, P2, P3, P4, P5, P6, P7, conforme representado na tabela 1, próximo à cidade de Paulino Neves-MA, durante o período de novembro de 2021 a novembro de 2022. Os dados incluem

informações sobre velocidade e direção média do vento a cada 10 minutos, abrangendo alturas a cada 10 metros de 40 metros a 200 metros e 20 metros de 200 metros a 260 metros. Esta informação é fundamental para analisar as complexas interações entre fatores meteorológicos e velocidade do vento no modelo de árvore de decisão.

Tabela 1 – Localização dos Pontos de Medição e Proximidade à Costa

Ponto	Localização	Período	Qtd. Obs.	Dist. (km)	Pluv. (mm)
P0	-2.694107, -42.554807	09/11/21 a 15/12/21	95.540	1,6	116,46
P1	-2.724877, -42.575182	16/09/21 a 09/11/21	160.436	5,7	6,18
P2	-2.725162, -42.606507	15/12/21 a 27/01/22	123.480	7,8	122,27
P3	-2.733535, -42.589530	28/01/22 a 18/04/22	140.260	7,1	129,26
P4	-2.759033, -42.807133	20/04/22 a 13/06/22	139.460	25,28	133,89
P5	-2.787355, -42.855720	15/06/22 a 27/07/22	100.960	31,92	21,28
P6	-2.733537, -42.589533	29/07/22 a 15/09/22	129.520	7,1	2,25
P7	-2.724997, -42.604932	16/09/22 a 08/11/22	150.600	7,8	9,43

As abreviações utilizadas são: Qtd. Obs. (Quantidade de Observações), Dist. (Distância em quilômetros até a costa), Pluv. (Pluviômetro em média mensal).

Durante o processo de organização dos dados dos pontos mencionados na Tabela 1, foram aplicados os seguintes critérios:

- Pontos de medição P3, P4 e P5 foram excluídos da análise quando a ausência de dados se estendeu por mais de dois dias consecutivos. Essa medida foi tomada devido à falta prolongada de informações, comprometendo a precisão da avaliação das condições do vento nesses locais.
- Além disso, foram removidos registros dos dias em que o LIDAR permaneceu inativo por mais de duas horas consecutivas. Essa exclusão se justifica pela interrupção prolongada na coleta de dados, afetando a confiabilidade das informações obtidas.

Tabela 2 – Tabela de localização, período e quantidade de observações válidas.


Pontos	Localização Lat/Long	Período	Qtd. Obs. válidas	Pluv. (mm)
P0	-2.694118°, -42.554814°	12/11 a 11/12/21	83.500	130,97
P1	-2.724882°, -42.575183°	17/09 a 07/11/21	149.880	5,79
P2	-2.725162°, -42.606509°	16/12 a 27/01/22	120.980	108,10
P6	-2.733544°, -42.589539°	30/07/22 a 15/09/22	126.820	2,27
P7	-2.725006°, -42.604936°	16/09/22 a 08/11/22	146.840	2,68

As abreviações utilizadas são: Qtd. Obs. (Quantidade de Observações válidas), Pluv. (Pluviômetro em média mensal).

Conforme os dados apresentados na Tabela 2, os pontos P0, P1, P2, P6 e P7 representadas por marcações em azul no mapa, foram selecionados após a aplicação dos

critérios de filtragem. Estes pontos representam as localizações onde as medições foram mais consistentes e confiáveis ao longo do período de análise. A Figura 6 fornece uma visualização geográfica desses pontos de medição.

Figura 6 – Mapa dos pontos de medição na área de estudo em Paulino Neves-MA, Brasil.



3.4 Desenvolvimento do modelo

No desenvolvimento dos modelos, além das variáveis de altura, velocidade e direção do vento, variáveis temporais, incluindo dia, mês, ano, hora e minuto, foram incorporadas. Essa abordagem permite que os modelos considerem as variações temporais que podem influenciar significativamente as condições do vento. A modelagem para a previsão da velocidade do vento e a identificação de eventos de rampa foram conduzidas utilizando a técnica *TreeBagger* no Matlab. A eficácia desse modelo foi mensurada através de métricas específicas para regressão e classificação.


No contexto da regressão, empregaram-se as métricas RMSE, MAPE e o R^2 para avaliar a precisão e a confiabilidade das previsões.

Para a classificação de eventos de rampa de vento, optou-se pela utilização de métricas como a Matriz de Confusão, a acurácia e o *F1-Score*. A acurácia pode apresentar problemas quando há um desbalanceamento de classes, o que não é o caso neste trabalho. Ela é utilizada para proporcionar uma visão geral da qualidade do classificador. O *F1-Score* é particularmente relevante, pois representa uma medida harmônica entre a Precisão (*Precision*) e a Revocação (*Recall*), também conhecida como Sensibilidade), oferecendo um balanço entre a capacidade do modelo de identificar corretamente eventos de rampa e sua precisão em classificar tais eventos como verdadeiros.

O conjunto de dados foi dividido em subconjuntos de treinamento e teste, utilizando a técnica de validação cruzada do tipo k-Fold, onde o conjunto de dados é dividido aleatoriamente em k (com $k=10$) subconjuntos de tamanhos iguais. Em cada iteração, um destes subconjuntos é deixado de fora e o modelo é treinado com os outros k-1 subconjuntos [18]. Em seguida, o algoritmo é avaliado no subconjunto isolado, e o processo é repetido k vezes até que todos os subconjuntos sejam usados para validação do modelo. Esta técnica é empregada para avaliar o desempenho de modelos de aprendizado de máquina de forma mais robusta, mitigando o risco de *overfitting*. Ela proporciona uma estimativa mais precisa do desempenho do modelo em dados não vistos, conforme discutido por [54]. Para avaliar o desempenho e generalização do modelo o processo de treinamento envolveu a criação de múltiplas árvores de decisão, cada uma baseada em subconjuntos aleatórios de dados e recursos conforme discutidos por [55]. Após a preparação dos dados, foi desenvolvido um algoritmo baseado em *Random Forests* para prever a velocidade do vento em intervalos correspondentes a diferentes horizontes de previsão. Os intervalos de previsão incluem o horizonte 10, 20, 30, 40, 50 60 minutos classificado como “muito curto prazo” (abrangendo alguns segundos a 10 minutos), curto prazo (20 a 60 minutos).

O processo de validação cruzada aplicado a um modelo de árvore de regressão e classificação segue os passos abaixo. O processo também é representado na Figura 7:

Figura 7 – Conjuntos de treinamento usando validação cruzada com *k-folds*



Fonte: [56]

- Divisão de dados: O conjunto total de dados é dividido aleatoriamente em 10 partes idênticas conhecidas como dobras.

- **Treinamento e Teste:** O modelo de árvore de regressão/classificação é treinado em 9 das dobras e testado na dobra restante. Este procedimento é repetido 10 vezes para garantir que cada dobra seja usada uma vez como conjunto de teste.
- **Métricas de Avaliação:** Para avaliar o desempenho do modelo, utilizam-se métricas específicas em cada iteração. Na regressão, são o RMSE, R^2 e MAPE. Em classificação, aplica-se a Matriz de Confusão, Acurácia e F1-Score. Estas métricas quantificam a precisão e a capacidade de generalização do modelo.
- **Métricas Médias:** As métricas de avaliação coletadas em cada iteração são combinadas por meio do cálculo da média para regressão e pela escolha dos valores mais votados para classificação. Isso visa obter uma estimativa abrangente do desempenho do modelo.
- **Seleção de Modelo:** Com base nas métricas de avaliação, são comparados diferentes modelos de árvore de regressão/classificação e os parâmetros do modelo são ajustados para encontrar a melhor configuração.

Após a realização da previsão da velocidade do vento utilizando o método de regressão baseado em RF, procedeu-se à classificação das velocidades do vento com base na equação 3.1 que foi derivada da definição 4 de secção 2.1. Esta classificação foi desenvolvida para realizar a previsão de rampa de vento. Para a definição de evento de rampa de vento, adotou-se uma variação percentual da velocidade do vento de 20%, sendo calculada utilizando a seguinte fórmula:

$$\text{Variação Percentual} = \left(\frac{V(t + \Delta t) - V(t)}{V(t)} \times 100 \right) \quad (3.1)$$


onde $V(t)$ representa a velocidade do vento no tempo inicial t , e $V(t + \Delta t)$ denota a velocidade do vento em um tempo subsequente, sendo Δt o intervalo de tempo considerado. Com base nesta fórmula, estabelecem-se duas categorias distintas:

1. **Rampa Crescente:** Caracterizada quando a variação percentual excede 20%, ou seja, $\text{Variação Percentual} > 20\%$.
2. **Rampa Decrescente:** Definida quando a variação percentual é inferior a -20%, isto é, $\text{Variação Percentual} < -20\%$.

Esta classificação permite uma análise detalhada das tendências no comportamento da velocidade do vento, sendo crucial para aplicações como a otimização de operações de parques eólicos e estudos relacionados à dinâmica atmosférica.

A metodologia completa desse estudo é ilustrada pela Figura 8

Figura 8 – Fluxograma da metodologia proposta.



4 Resultados

Neste capítulo, apresentam-se os resultados das análises realizadas em cinco pontos de medição identificados como P0, P1, P2, P6 e P7, localizados na cidade de Paulino Neves, Maranhão.

Durante a pesquisa, analisou-se a variabilidade das velocidades do vento ao longo do tempo, visando prever as velocidades do vento em diferentes alturas e horizontes de tempo. Além disso, objetivou-se classificar e prever eventos de rampas nos pontos de medição. Para a avaliação da velocidade do vento em diferentes altitudes, foram selecionadas quatro alturas distintas: 50 metros, 100 metros, 150 metros e 200 metros, que são representativas de todo o perfil observado. No entanto, foram colocadas nos Apêndices A, B e C tabelas com métricas de todas as alturas e períodos de previsão.

Também investigou-se a relação entre a velocidade do vento e a distância do litoral, levando em consideração a influência resultante da rugosidade do terreno e das variações térmicas da superfície, tanto durante o período chuvoso quanto no período de estiagem. As análises foram feitas do litoral adentrando no continente, de acordo com cada ponto, do mais próximo da costa até o mais distante.

O ponto P0 está localizado próximo à costa, com medições realizadas durante o período chuvoso. Os pontos P1, P2, P6 e P7 são escalonados em relação à distância da linha da costa, apresentando uma rugosidade de superfície similar em uma região de morfologia terrestre complexa, caracterizada por cristas e depressões de dunas estabilizadas pela vegetação, conforme documentado por [57].

O ponto P1 está situado mais no interior em relação à costa do que o ponto P0, onde as medições foram realizadas durante o período seco. Este ponto é influenciado pela rugosidade do terreno e pela variação térmica da superfície.

O ponto P6, situado mais no interior do continente do que o ponto P1 e com características similares a este, também é afetado pela rugosidade do terreno e pela variação térmica. Assim como no ponto P1, as medições ocorreram durante o período seco.

O ponto P2, o mais distante da costa entre os pontos de medição, foi escolhido para as medições durante o período chuvoso. Situado mais no interior do continente, ele é o mais afetado pela rugosidade do terreno.


Por fim, o ponto P7 está situado nas proximidades do local onde foi registrado o ponto P2, porém as medições foram tomadas durante o período seco na região, permitindo uma análise comparativa da influência da chuva no desempenho do modelo entre ambos os pontos.

Os resultados demonstram que a precisão das previsões é impactada pela rugosidade do terreno e pela variação térmica da superfície. À medida que se afastam da costa, os pontos são mais afetados pela rugosidade do terreno. Durante o período chuvoso, ocorrem variações abruptas na velocidade e direção do vento, reduzindo o contraste térmico entre a superfície do continente e a do mar. A formação de lagoas no período da chuva também é um fator contribuinte para diminuir a variação de temperatura entre o continente e o oceano. No entanto, o modelo *Random Forest* provou ser eficaz na previsão de eventos de vento em diversas condições geográficas e climáticas, o que reafirma a robustez do modelo em diferentes cenários, conforme detalhado a seguir na análise de cada ponto.

4.1 Resultados e análises para o ponto P0

As medições no ponto P0 registraram uma velocidade média do vento de 9,77 m/s, atingindo um pico máximo de 15,37 m/s no dia 10 de dezembro de 2021, às 08:40, e um valor mínimo de 0,36 m/s em 15 de novembro de 2021, às 03:30. A posição geográfica do ponto de medição, situado nas proximidades da costa, oferece um cenário propício para a obtenção das características com influência mínima das forçantes continentais. É importante destacar que as medições foram realizadas no início do período chuvoso da região, que apresentou uma precipitação média mensal de 130,97 mm. Este fator pode influenciar tanto a intensidade quanto a direção dos ventos. Os detalhes específicos do período de medição estão catalogados na Tabela 2, em que foram utilizadas as métricas RMSE, R^2 e MAPE.

Figura 9 – Estimativa do vento em 60 minutos no ponto P0.



O gráfico apresentado na figura 9 ilustra as variações na velocidade do vento previstas e observadas em três alturas distintas: 50m, 150m e 260m para o horizonte de 60

minutos. Percebe-se que a acentuada flutuação observada no término da noite e começo da manhã tem seu impacto atenuado em elevações mais altas. Esse fenômeno ocorre, muito provavelmente, devido à menor influência da brisa local (seja marítima ou terrestre) nessas altitudes, alinhando-se às propriedades dos ventos alísios, os quais apresentam maior constância.

É relevante enfatizar que, embora o modelo tenha demonstrado uma notável eficácia na previsão das velocidades do vento para o ponto P0, é preciso considerar que a localização específica desse ponto se encontra em proximidade com a costa, o que diminui os efeitos da rugosidade do terreno e das variações térmicas causadas pelo aquecimento e resfriamento da superfície do continente. Além disso, é importante observar que o período de medição coincidiu com o início do período chuvoso na região, o que pode acarretar em um maior erro na previsão, tendo em vista as variações bruscas de vento causadas por tempestades inerentes à proximidade da zona de convergência intertropical (ZCIT).

Tabela 3 – Desempenho do Modelo em Diferentes Alturas e Tempos no ponto P0

Altura (m)	Tempo (10 min)			Tempo (20 min)			Tempo (30 min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
50	0,4168	0,9571	3,54%	0,4898	0,9408	4,12%	0,5059	0,9369	4,36%
100	0,2845	0,9793	2,13%	0,3273	0,9726	2,45%	0,3345	0,9714	2,53%
150	0,2265	0,9854	1,64%	0,2697	0,9794	1,91%	0,2804	0,9777	1,94%
200	0,2712	0,9772	1,88%	0,3165	0,9690	2,16%	0,3186	0,9686	2,20%
Altura (m)	Tempo (40 min)			Tempo (50 min)			Tempo (60 min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
50	0,5244	0,9322	4,54%	0,5280	0,9313	4,57%	0,5236	0,9325	4,59%
100	0,3388	0,9707	2,67%	0,3442	0,9697	2,68%	0,3440	0,9698	2,70%
150	0,2700	0,9793	1,97%	0,2685	0,9796	1,97%	0,2741	0,9787	1,96%
200	0,3079	0,9707	2,20%	0,3065	0,9710	2,20%	0,3134	0,9697	2,19%

Para uma visualização completa com todas as alturas e horizontes temporais, consulte o Apêndice A.

Ao analisar os resultados apresentados na Tabela 3 com relação ao ponto P0, verifica-se uma diminuição no valor do RMSE à medida que a altura aumenta. Esse padrão sugere que o modelo apresenta um desempenho globalmente superior em alturas mais elevadas, independentemente do horizonte temporal. A título de exemplo, para um horizonte de previsão de 10 minutos, o RMSE na altura de 50 metros é de 0,4168 e de 0,2713 a 200 metros. Já para um horizonte de 30 minutos, o RMSE é de 0,5059 a 50 metros e de 0,3186 a 200 metros. Essa tendência se mantém consistente em todos os horizontes temporais investigados.

O coeficiente de determinação R² tende a permanecer em níveis elevados em todas as alturas, sugerindo que o modelo RF consegue explicar a variação dos dados, independentemente da altura e do horizonte temporal. Ao analisar o horizonte de 60 minutos

a uma altura de 50 metros, o R^2 alcança o valor de 0,932; em 100 metros, é de 0,969; em 150 metros, é de 0,978; e em 200 metros, é de 0,9697. Entretanto, é relevante notar que o R^2 tende a diminuir à medida que o horizonte temporal aumenta, indicando uma tendência do modelo em cometer mais erros à medida que o horizonte de previsão se amplia. Essa tendência se reflete no MAPE, que aumenta à medida que o horizonte de tempo se estende. Para uma altura de 200 metros e um horizonte de previsão de 10 minutos, o MAPE é de 1,88%. Esse valor aumenta para 2,20% em 30 minutos e 2,19% em 60 minutos. Portanto, o MAPE indica que as previsões se tornam mais precisas à medida que o horizonte de previsão aumenta, demonstrando um desempenho melhor do modelo em alturas mais elevadas.

Tabela 4 – Métrica Classificação para o ponto P0

Altura	Tempo 10 (min)			Tempo 20 (min)			Tempo 30 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
50	0,966	0,970	0,968	0,939	0,944	0,942	0,971	0,972	0,972
100	0,969	0,968	0,969	0,980	0,980	0,980	0,959	0,962	0,961
150	0,964	0,969	0,967	0,946	0,957	0,952	0,974	0,979	0,977
200	0,990	0,990	0,990	0,986	0,988	0,987	0,987	0,987	0,987
Altura	Tempo 40 (min)			Tempo 50 (min)			Tempo 60 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
50	0,967	0,972	0,970	0,956	0,957	0,957	0,941	0,945	0,943
100	0,944	0,956	0,950	0,971	0,972	0,972	0,950	0,955	0,953
150	0,943	0,948	0,946	0,989	0,989	0,989	0,950	0,962	0,957
200	0,985	0,987	0,986	0,952	0,961	0,957	0,968	0,972	0,970

Para uma visualização completa com todas as alturas e horizontes temporais, consulte o Apêndice B.

Os valores de F1-Score para eventos de rampa crescente e decrescente servem como indicadores da capacidade do modelo em prever com precisão esses dois tipos de eventos. Como observado na Tabela 4, os F1-Scores são notavelmente elevados em todos os intervalos de tempo analisados. Para os eventos de rampa crescente em um intervalo de 20 minutos, os F1-score Crescente (F1SC) variam de 0,939 a 0,986. Da mesma forma, para os eventos rampa decrescente, os F1-score decrescente (F1SD) variam de 0,944 a 0,988. Esses valores elevados de F1-Score tanto para eventos de crescente quanto de decrescente destacam a precisão do modelo na previsão de eventos de rampa de vento, independentemente de sua direção.

A Acurácia, também apresentada na Tabela 4, é uma métrica que reflete a capacidade geral do modelo em classificar corretamente os eventos. Nos intervalos de 60 minutos, para as quatro alturas em destaque, a acurácia varia de 0,943 a 0,970. Esses altos valores de acurácia em todos os intervalos sugerem que o modelo é eficaz em identificar corretamente a maioria dos eventos de rampa de vento.

Tabela 5 – Matriz de confusão para o ponto P0

Altura	Tempo (10 min)				Tempo (20 min)				Tempo (30 min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
50	64	2	2	56	51	5	1	46	53	3	0	50
100	61	1	3	63	50	0	2	49	51	1	3	47
150	62	4	0	54	55	3	2	44	47	1	1	38
200	51	0	1	51	40	1	0	35	39	0	1	38
Altura	Tempo (40 min)				Tempo (50 min)				Tempo (60 min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
50	53	2	1	44	45	3	1	43	52	4	2	48
100	54	2	3	42	52	0	3	51	53	4	1	48
150	46	1	4	41	47	0	1	44	50	3	1	38
200	39	1	0	33	37	3	0	30	35	1	1	30

Para uma visualização completa com todas as alturas e horizontes temporais, consulte o Apêndice C.

A matriz de confusão revela que a soma dos eventos de falso positivo e falso negativo ficou abaixo de 5% para todas as alturas e períodos de previsão, exceto para a previsão de 60 minutos a 50 metros, onde alcançou 5,6%, conforme detalhado na Tabela 5. Este desempenho destaca-se particularmente no intervalo de 20 minutos, onde o modelo se mostrou altamente eficaz. Na altura de 100 metros, por exemplo, o modelo identificou corretamente 50 eventos de rampa crescente e 49 eventos de rampa decrescente, com apenas 2 eventos de rampa crescente classificados incorretamente como decrescente.

4.2 Resultados e análises para o ponto P1

No ponto P1, conforme indicado pela tabela 2, foram coletadas 146.840 observações válidas ao longo de 51 dias de medição. Este intervalo coincide com a estação seca na região estudada, que registrou uma precipitação média mensal de 5,79 mm. Durante esse período, a velocidade média do vento foi de 9,47 m/s. Os picos de velocidade máxima foram registrados em 30/09/2021 às 17:50, em 03/10/2021 às 02:50 e em 04/11/2021 às 15:40, alcançando 17,02 m/s. A velocidade mínima, por sua vez, ocorreu em 30/09/2021 às 06:00, atingindo 1,83 m/s.

O gráfico apresentado na figura 10 ilustra as variações na velocidade do vento previstas e observadas no Ponto P1 em três alturas distintas: 50m, 150m e 260m para o horizonte de 60 minutos. Percebe-se que a brusca variação que acontece no final do período noturno e início da manhã é menos sentida em maiores alturas, muito provavelmente por serem menos impactadas pela brisa local (marítima /terrestre), seguindo as características dos ventos alísios, os quais são mais constantes.

Figura 10 – Estimativa do vento em 60 minutos no ponto P1.



Tabela 6 – Métrica de regressão em Diferentes Alturas e Tempos no ponto P1

Altura (m)	Tempo (10 min)			Tempo (20 min)			Tempo (30 min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
50	0,5403	0,891	4,95	0,6012	0,865	5,51	0,6265	0,854	5,74
100	0,4827	0,913	3,85	0,5281	0,896	4,17	0,5412	0,891	4,29
150	0,4063	0,942	3,00	0,4362	0,933	3,19	0,4443	0,931	3,24
200	0,3900	0,950	2,84	0,4162	0,943	3,01	0,4281	0,939	3,07
Altura (m)	Tempo (40 min)			Tempo (50 min)			Tempo (60 min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
50	0,6364	0,849	5,88	0,6351	0,850	5,90	0,6378	0,849	5,91
100	0,5454	0,889	4,33	0,5487	0,888	4,37	0,5478	0,889	4,38
150	0,4366	0,933	3,20	0,4382	0,933	3,22	0,4345	0,934	3,20
200	0,4258	0,940	3,06	0,4192	0,942	3,03	0,4139	0,943	3,02

Para uma visualização completa com todas as alturas e horizontes temporais, consulte o Apêndice A.

Conforme a Tabela 6, observa-se que a precisão das previsões para este ponto é influenciada tanto pela rugosidade do terreno quanto pela distância do litoral. Isso se reflete nos valores de RMSE, sendo inicialmente altos, mas diminuem de forma notável à medida que a medição é feita em alturas maiores. Além disso, à medida que se expande o horizonte de tempo analisado, o erro tende a aumentar. No horizonte de 10 minutos, o RMSE é de 0,5403 a 50 metros, reduzindo para 0,39 a 200 metros. Para o horizonte de 60 minutos, o RMSE é de 0,6378 a 50 metros e diminui para 0,4192 a 200 metros, em todas as altura e erro foi menor que 0,7 m/s. A altura de 200 metros apresenta os menores valores de RMSE,

o R^2 no pior cenário, horizontes de 60 min, a média ficou abaixo de 0,904, demonstrando ser eficaz em termos preditivos. O MAPE ficou abaixo de 6% também decresce com o aumento da altura, corroborando a maior eficiência do modelo em altitudes elevadas.

Tabela 7 – Métrica Classificação (F1 Score e Acurácia) para o ponto P1

Altura	Tempo 10 (min)			Tempo 20 (min)			Tempo 30 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
50	0,994	0,993	0,994	0,988	0,992	0,990	0,964	0,963	0,963
100	0,993	0,992	0,992	0,987	0,988	0,988	0,973	0,971	0,972
150	1,000	1,000	1,000	0,971	0,971	0,971	0,971	0,970	0,970
200	0,972	0,971	0,972	1,000	1,000	1,000	0,945	0,949	0,947
Altura	Tempo 40 (min)			Tempo 50 (min)			Tempo 60 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
50	0,984	0,986	0,985	0,968	0,968	0,968	0,917	0,957	0,944
100	0,980	0,986	0,984	0,954	0,961	0,958	0,963	0,969	0,966
150	0,983	0,985	0,984	0,984	0,981	0,983	0,972	0,964	0,969
200	0,951	0,947	0,949	0,945	0,949	0,947	0,941	0,933	0,938

Para uma visualização completa com todas as alturas e horizontes temporais, consulte o Apêndice B.

A análise da Tabela 7 revela o desempenho do modelo de classificação em diferentes alturas e horizontes temporais. Observa-se que o F1 Score crescente e decrescente é mais assertivo no horizonte de 10 minutos e comete mais erros quando o horizonte se estende. Isso ocorre para todas as alturas. A Acurácia segue a mesma tendência nos horizontes temporais analisados. Notavelmente, a altura de 150 metros e o horizonte temporal de 10 minutos alcançam a perfeição (F1 Score e Acurácia de 1), evidenciando a capacidade excepcional do modelo em classificar corretamente as rampas de vento neste cenário específico. A leve redução no desempenho com o aumento do horizonte temporal sugere uma maior dificuldade em classificar rampas de vento para previsões mais longas, embora os valores permaneçam impressionantemente altos, ainda que exista variações com a altura e tempo os valores nunca são inferiores a 0,9.

A Tabela 8 apresenta a matriz de confusão para a classificação de eventos de rampa de vento em diversas alturas e horizontes temporais. A soma dos eventos de FP e FN permaneceu abaixo de 3% para os horizontes de 10 e 20 minutos em todas as alturas. No entanto, para o horizonte de 30 minutos a uma altura de 200 metros, essa soma atingiu 5,26%, e com o aumento do horizonte temporal, chegou a 6,25%. A análise dos VP, FN, FP e VN demonstra que o modelo conserva uma alta precisão em todos os cenários testados. Em particular, a eficiência do modelo é mais notável nos horizontes temporais mais curtos (10 a 30 minutos), onde há uma minimização nos números de FN e FP. Embora essa eficácia decresça levemente para horizontes temporais mais longos (40 a 60 minutos), indicado por um pequeno aumento nos índices de FP e FN, os valores de VP e VN continuam elevados.

Tabela 8 – Tabela de Matriz de confusão para o ponto P1

Altura	Tempo (10 min)				Tempo (20 min)				Tempo (30 min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
50	72	1	0	81	62	1	0	41	39	2	1	40
100	61	1	0	67	42	1	0	39	33	0	2	36
150	63	0	0	59	34	1	1	33	32	1	1	33
200	51	1	2	53	28	0	0	28	28	2	1	26
Altura	Tempo (40 min)				Tempo (50 min)				Tempo (60 min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
50	34	0	1	31	30	1	1	30	45	2	2	22
100	36	1	0	24	37	1	2	31	31	1	1	26
150	32	0	1	29	26	1	0	31	27	1	1	35
200	27	2	1	29	28	1	2	26	21	1	2	24

Para uma visualização completa com todas as alturas e horizontes temporais, consulte o Apêndice C.

Isso sinaliza que o modelo mantém uma boa desempenho na classificação de eventos de rampa, inclusive em previsões de longo prazo. A média de erros para 60min foi de 4,2%


4.3 Resultados e análises para o ponto P6

As medições no ponto P6, registraram uma velocidade média do vento de 8,63 m/s. Observou-se que os picos de velocidade máxima foram atingidos no dia 4 de setembro de 2022, às 22:40, alcançando 16,42 m/s, enquanto o registro da velocidade mínima ocorreu no dia 19 de agosto de 2022, às 03:20, atingindo 0,49 m/s no período seco da região com uma precipitação média mensal de 2,27 mm.

O gráfico da Figura 11 apresenta as variações nas velocidades do vento previstas e observadas em três alturas distintas: 50m, 150m e 260m, considerando um horizonte de 60 minutos.

A influência das brisas pode ser observada nos padrões oscilatórios diários das velocidades do vento. Durante as primeiras horas da manhã, há um aumento intenso na velocidade do vento, provavelmente devido ao aquecimento da superfície do continente que leva à intensificação da brisa marítima. A partir do pôr do sol há queda gradual da velocidade, acelerando durante a madrugada, em função da desintensificação da brisa marítima e ao surgimento de uma tênue brisa terrestre. Os ventos próximos à superfície são mais afetados por este fenômeno em função do processo convectivo que se origina na superfície. Os ventos em maiores alturas, menos afetados pela brisa, mantém as características dos ventos alísios. O modelo consegue acompanhar bem as mudanças bruscas e suaves desta variação de um ciclo diário, mesmo na previsão de tempo mais estendida, de sessenta minutos.

Figura 11 – Estimativas do vento em 60 minutos no ponto P6.



O ponto P6 fica a cerca de 2 km do ponto P1 na direção do interior do continente e os dois tiveram observações em época de seca. Os valores de RMSE, R², MAPE, F1 score e Acurácia apresentados nas tabelas 9, 10 e 11, apresentaram valores semelhantes entre os dois pontos, mostrando a estabilidade e coerência do modelo para situações semelhantes. Da mesma forma que as métricas anteriores, a matriz de confusão também apresentou valores semelhantes, com um desempenho um pouco melhor para P6. Estas pequenas variações estatísticas entre estes pontos, da ordem de 5%, devem ser consideradas com cuidado, tendo em vista que o período de observação foi pequeno.

Tabela 9 – Desempenho do Modelo em Diferentes Alturas e Tempos no ponto P6

Altura (m)	Tempo (10 min)			Tempo (20 min)			Tempo (30 min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
50	0,4634	0,935	4,80	0,5281	0,916	5,56	0,5694	0,903	6,05
100	0,4105	0,944	3,59	0,4665	0,927	4,12	0,4915	0,919	4,35
150	0,3836	0,954	3,12	0,4298	0,942	3,48	0,4448	0,938	3,62
200	0,3815	0,960	3,09	0,4310	0,949	3,42	0,4459	0,945	3,54
Altura (m)	Tempo (40 min)			Tempo (50 min)			Tempo (60 min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
50	0,5860	0,897	6,23	0,6059	0,890	6,51	0,6073	0,889	6,54
100	0,5037	0,915	4,45	0,5167	0,911	4,60	0,5131	0,912	4,57
150	0,4553	0,935	3,69	0,4690	0,931	3,78	0,4702	0,931	3,79
200	0,4532	0,944	3,60	0,4605	0,942	3,63	0,4689	0,940	3,70

Para uma visualização completa com todas as alturas e horizontes temporais, consulte o Apêndice A.

Tabela 10 – Métrica Classificação para o ponto P6

Altura	Tempo 10 (min)			Tempo 20 (min)			Tempo 30 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
50	0,991	0,991	0,991	0,976	0,977	0,977	0,993	0,994	0,993
100	0,983	0,984	0,983	0,986	0,986	0,986	0,968	0,971	0,969
150	0,984	0,983	0,984	0,992	0,992	0,992	0,978	0,980	0,979
200	0,994	0,994	0,994	0,990	0,991	0,991	0,944	0,960	0,953
Altura	Tempo 40 (min)			Tempo 50 (min)			Tempo 60 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
50	0,991	0,993	0,992	0,968	0,969	0,968	0,976	0,972	0,974
100	0,965	0,966	0,965	0,938	0,959	0,951	0,966	0,973	0,970
150	0,947	0,958	0,953	1,000	1,000	1,000	1,000	1,000	1,000
200	0,921	0,932	0,927	1,000	1,000	1,000	0,974	0,976	0,975

Para uma visualização completa com todas as alturas e horizontes temporais, consulte o Apêndice B.

Tabela 11 – Matriz de confusão para o ponto P6

Altura	Tempo (10 min)				Tempo (20 min)				Tempo (30 min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
50	115	1	1	115	84	2	2	83	77	1	0	67
100	90	1	2	88	68	1	1	72	50	2	1	45
150	85	2	1	94	59	0	1	60	49	2	0	44
200	87	1	0	78	57	0	1	52	48	3	1	34
Altura	Tempo (40 min)				Tempo (50 min)				Tempo (60 min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
50	70	0	1	58	62	3	1	60	53	1	2	61
100	42	1	2	41	47	3	1	30	54	1	2	42
150	46	3	1	36	42	0	0	43	49	0	0	37
200	41	5	1	35	36	0	0	38	41	1	1	37

Para uma visualização completa com todas as alturas e horizontes temporais, consulte o Apêndice C.


4.4 Resultados e análises para o ponto P2 e P7

Considerando que os pontos P2 e P7 compartilham a mesma localização, mas com medições realizadas em condições climáticas distintas, o ponto P2 durante uma época chuvosa, registrando precipitações de 108,10 mm, e o P7 em um período seco, com precipitações de 2,68 mm, será realizada uma análise comparativa entre os dois.


As medições no ponto P2 indicaram uma velocidade média do vento de 7,78 m/s, com picos de velocidade máxima alcançando 15,75 m/s no dia 16 de dezembro de 2021, às 09:10. A velocidade mínima registrada foi de apenas 0,10 m/s, no dia 13 de janeiro de 2022, às 07:10.

No ponto P7, a velocidade média do vento foi de 10,14 m/s, com picos máximos de 17,21 m/s observados em 10 de outubro de 2022, às 02:30, e em 03 de novembro de 2022, às 17:30. A menor velocidade registrada foi de 0,52 m/s, em 06 de novembro de 2022, às 23:00.

Figura 12 – Estimativas do vento em 60 minutos nos pontos P2 e P7.



(a) Estimativa do vento em 60 minutos no ponto P2.



(b) Estimativa do vento em 60 minutos no ponto P7.

O gráfico na Figura 12a e 12b ilustra as variações nas velocidades do vento previstas e observadas em três alturas distintas: 50m, 150m e 260m, para um horizonte de 60 minutos. Observa-se que o fenômeno de mudança de velocidade do vento no ciclo diurno, já discutido anteriormente, acontece de maneira um pouco diferente nos exemplos amostrados. Em P7, com uma variação de velocidade maior e em menor espaço de tempo, este fenômeno

apresenta-se de forma mais abrupta. No entanto, a resposta do modelo demonstra que o mesmo consegue prever bem as variações nas duas condições climáticas.

Tabela 12 – Comparação do Desempenho dos Modelos nos Pontos P2 e P7 em Diferentes Alturas e Tempos

(a) Métrica de regressão no ponto P2

Altura (m)	Tempo (10 min)			Tempo (20 min)			Tempo (30 min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
50	0,5188	0,959	6,72	0,6044	0,945	8,13	0,6289	0,940	8,67
100	0,4307	0,972	4,87	0,4958	0,963	5,74	0,4982	0,963	5,87
150	0,3926	0,976	4,20	0,4408	0,970	4,79	0,4429	0,970	4,99
200	0,4054	0,974	4,04	0,4746	0,964	4,76	0,4852	0,963	4,98
Altura (m)	Tempo (40 min)			Tempo (50 min)			Tempo (60 min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
50	0,6367	0,939	9,06	0,6300	0,940	9,16	0,6382	0,938	9,32
100	0,4958	0,963	5,90	0,4928	0,963	5,93	0,4948	0,963	5,92
150	0,4443	0,970	5,05	0,4389	0,970	5,02	0,4462	0,969	5,09
200	0,4811	0,963	4,97	0,4696	0,965	4,87	0,4705	0,965	4,95

(b) Métrica de regressão no ponto P7

Altura (m)	Tempo (10 min)			Tempo (20 min)			Tempo (30 min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
50	0,5275	0,937	4,39	0,5782	0,925	4,82	0,5925	0,921	4,90
100	0,4217	0,961	3,10	0,4566	0,955	3,33	0,4599	0,954	3,36
150	0,3546	0,974	2,52	0,3772	0,970	2,67	0,3817	0,970	2,70
200	0,3599	0,974	2,55	0,3835	0,970	2,71	0,3855	0,970	2,73
Altura (m)	Tempo (40 min)			Tempo (50 min)			Tempo (60 min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
50	0,6032	0,919	4,99	0,6043	0,918	5,03	0,6040	0,919	5,05
100	0,4706	0,952	3,43	0,4675	0,953	3,44	0,4666	0,953	3,46
150	0,3847	0,969	2,72	0,3830	0,970	2,75	0,3788	0,970	2,75
200	0,3919	0,969	2,76	0,3885	0,970	2,76	0,3894	0,970	2,78

Para uma visualização completa com todas as alturas e horizontes temporais, consulte o Apêndice A.

A Tabela 12a e 12b apresentam as métricas de regressão para diferentes alturas (50, 100, 150, 200 metros) e horizontes temporais (10 a 60 minutos) nos pontos P2 e P7, localizados em uma área de morfologia complexa. Nas métricas de regressão, RMSE, R² e MAPE, os dois pontos apresentam um desempenho similar do modelo, com ligeira vantagem para o ponto P7 (período de seca). Por outro lado, nas métricas de classificação, F1 score e Acurácia (Tabelas 13a e 13b), o ponto P7 apresenta um desempenho inferior, na faixa de um décimo, principalmente para os intervalos de previsão acima de 40 min, enquanto o ponto P2 apresenta valores muito próximos ao ideal (1).

Tabela 13 – Métricas Classificação nos Pontos P2 e P7 em Diferentes Alturas e Tempos

(a) Métrica Classificação para o ponto P2

Altura	Tempo 10 (min)			Tempo 20 (min)			Tempo 30 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
50	0,990	0,989	0,989	0,992	0,993	0,993	0,989	0,988	0,989
100	0,991	0,991	0,991	0,996	0,996	0,996	0,992	0,992	0,992
150	0,991	0,991	0,991	0,972	0,974	0,973	0,979	0,979	0,979
200	0,990	0,991	0,990	0,990	0,991	0,991	0,994	0,994	0,994
Altura	Tempo 40 (min)			Tempo 50 (min)			Tempo 60 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
50	1,000	1,000	1,000	0,997	0,997	0,997	1,000	1,000	1,000
100	0,996	0,996	0,996	0,996	0,996	0,996	0,996	0,996	0,996
150	0,975	0,976	0,976	0,988	0,988	0,988	0,988	0,989	0,989
200	0,980	0,977	0,979	0,995	0,994	0,995	0,995	0,995	0,995

(b) Métrica Classificação para o ponto P7

Altura	Tempo 10 (min)			Tempo 20 (min)			Tempo 30 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
50	0,956	0,958	0,957	0,907	0,915	0,911	0,938	0,944	0,941
100	0,974	0,977	0,976	0,911	0,925	0,919	0,951	0,955	0,953
150	0,981	0,984	0,983	0,928	0,933	0,931	0,929	0,950	0,941
200	0,952	0,957	0,955	0,930	0,921	0,925	0,824	0,885	0,860
Altura	Tempo 40 (min)			Tempo 50 (min)			Tempo 60 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
50	0,912	0,943	0,931	0,851	0,920	0,896	0,885	0,929	0,912
100	0,857	0,873	0,865	0,884	0,930	0,912	0,774	0,916	0,877
150	0,898	0,902	0,900	0,935	0,944	0,940	0,824	0,816	0,820
200	0,816	0,830	0,824	0,810	0,778	0,795	0,851	0,857	0,854

Para uma visualização completa com todas as alturas e horizontes temporais, consulte o Apêndice B.

Tabela 14 – Tabela de Matriz de confusão nos Pontos P2 e P7 em Diferentes Alturas e Tempos

(a) Matriz de confusão para o ponto P2

Altura	Tempo (10 min)				Tempo (20 min)				Tempo (30 min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
50	178	0	4	198	148	2	0	130	125	1	2	133
100	174	1	2	164	132	1	0	130	122	1	1	120
150	165	1	2	174	132	6	1	122	116	4	1	116
200	158	1	2	144	115	2	0	102	90	0	1	87
Altura	Tempo (40 min)				Tempo (50 min)				Tempo (60 min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
50	144	0	0	135	143	1	0	144	145	0	0	150
100	131	1	0	139	138	1	0	126	139	1	0	142
150	124	3	3	115	120	1	2	120	133	3	0	125
200	86	3	1	99	88	1	0	101	108	0	1	105

(b) Matriz de confusão para o ponto P7

Altura	Tempo (10 min)				Tempo (20 min)				Tempo (30 min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
50	68	1	5	65	43	6	2	39	42	1	4	38
100	63	3	0	57	43	5	2	36	32	1	2	29
150	61	1	1	53	35	4	1	32	38	3	1	26
200	55	3	2	50	29	1	4	33	23	5	1	14
Altura	Tempo (40 min)				Tempo (50 min)				Tempo (60 min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
50	41	4	1	26	40	5	2	20	39	6	0	23
100	24	2	5	21	33	2	3	19	38	7	0	12
150	23	2	3	22	34	3	1	29	20	5	4	21
200	22	5	4	20	14	2	6	17	21	5	2	20

Para uma visualização completa com todas as alturas e horizontes temporais, consulte o Apêndice C.

A matriz de confusão para os dois pontos (Tabelas 14a) e 14b)) apresentam resultado coerente com F1 Score, mostrando um desempenho excelente para o ponto P2 e inferior para o ponto P7. Em adição à comparação dos pontos P2 e P7 que estão na mesma localização em condições climáticas diferentes, também é feita a comparação dos resultados do ponto P7 com o ponto P6, os quais estão separados por cerca de 2 km e tiveram taxas de precipitação semelhantes. Observa-se que o ponto P6 teve um desempenho na matriz de confusão superior e em linha com os outros pontos. Isto trás o questionamento do desempenho do ponto P7 que teve bons valores de métricas de regressão e valores um pouco abaixo em métricas de classificação em comparação com localidades semelhantes. Acredita-se que o treinamento da *Random Forest* com um conjunto maior de dados pode trazer uma luz para esta discrepância encontrada no ponto 7.

5 Conclusão

A área em que foram realizados os experimentos do EOSOLAR, bem como os sensores utilizados, se mostraram de grande importância para uma análise detalhada de características inerentes a vários parques da região costeira e equatorial do Brasil.

Com a revisão bibliográfica ficou aparente que o modelo baseado em RF tem resultados promissores na previsão de curto prazo do perfil de vento, bem como na previsão das rampas de vento, que são uma consequência do prognóstico preciso do perfil do vento.

O uso de dados de perfil de vento em toda a extensão vertical atual e futura dos geradores eólicos, juntamente com a amostragem de dados de locais com diferentes rugosidades e posicionamentos em relação à linha de costa, tanto em condições secas quanto chuvosas, permitiu avaliar o desempenho do modelo em diversos cenários. As análises realizadas neste estudo destacam que as condições atmosféricas e geográficas têm um impacto direto na variação da velocidade do vento.

Em praticamente todas as situações, o modelo baseado em RF consegue, em sua maioria, entregar resultados satisfatórios. Foram construídos modelos de regressão e classificação para previsão em intervalos de 10, 20, 30, 40, 50 e 60 minutos. As métricas regressivas RMSE, R² e MAPE demonstram o excelente desempenho do modelo, mesmo diante da complexidade do terreno e da altura das medições. Adicionalmente, foi realizada uma avaliação classificatória, que também apresentou bons resultados de previsão. No entanto, ainda necessita de aprimoramento. O modelo RF emergiu como uma ferramenta valiosa na previsão e classificação de eventos de vento.

Conclui-se que a localização, as características topográficas e a altitude das medições são fatores determinantes para a acurácia das previsões de vento. O modelo RF se destacou como uma ferramenta promissora para a previsão e classificação de eventos de rampas.

5.1 Trabalhos Futuros

Entende-se que esta pesquisa pode ser estendida utilizando-se um conjunto maior de dados para treinamento e teste, incorporando a exploração de outros modelos de *Machine Learning* além do modelo *Random Forest* utilizado neste estudo. O sucesso observado com o modelo *Random Forest* sugere que técnicas como redes neurais profundas e máquinas de vetores de suporte podem oferecer novas perspectivas e aumentar a precisão da previsão de eventos de rampa. Pelo menos um ano adicional de dados seria recomendado para garantir uma maior consistência estatística ao avaliar esses novos modelos.

Outra possibilidade é aumentar o tempo de previsão para até 2 horas, dentro de um limite de precisão considerado aceitável pela indústria eólica, enquanto também se realiza uma análise de sensibilidade às variáveis meteorológicas. Dado o papel crítico das condições meteorológicas na geração de energia eólica, uma investigação mais aprofundada sobre como fatores como temperatura, pressão atmosférica e umidade afetam a precisão das previsões seria essencial para ajustar ainda mais as técnicas de previsão.

Também é recomendado que sejam usados dados de poucas alturas ou perfil teórico extrapolado, simulando uma torre anemométrica para comparar a eficiência do modelo com dados de perfil detalhados, como realizado neste trabalho. Desta forma, será possível avaliar a real contribuição de perfiladores verticais de vento na eficiência de modelos de previsão, enquanto se exploram estudos de caso em diferentes localizações geográficas. A variabilidade das condições climáticas e topográficas entre diferentes regiões sugere a necessidade de estudos de caso variados para avaliar a adaptabilidade e generalização do modelo *Random Forest* a diferentes ambientes, contribuindo para a otimização da previsão de eventos de rampa em uma gama mais ampla de cenários de energia eólica.

Finalmente, sugere-se a aplicação deste modelo de forma híbrida com modelos determinísticos, ajustados para a microrregião em questão, a fim de avaliar a capacidade de aumentar o tempo de previsão sem prejuízo da assertividade do modelo.

5.2 Artigos Publicados

- CRUZ, Josélio C. et al. Estado da Arte para Previsão de Eventos de Rampas Eólicas no Sistema de Energia. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, 24., Fortaleza, 2022. Anais [...] Sociedade Brasileira de Automática: Fortaleza, 2023. Disponível em: https://www.sba.org.br/cba2022/wp-content/uploads/artigos_cba2022/paper_3569.pdf.
- J. C. Cruz, D. Q. Oliveira, F. L. Albuquerque Neto and L. T. d. A. do Monte, "Analysis of a Wind Speed Prediction Model Based on Decision Trees". In: 2023 Workshop on Communication Networks and Power Systems (WCNPS), Brasília, Brazil, 2023, pp. 1-7, doi: 10.1109/WCNPS60622.2023.10344558.

Referências

- [1] Empresa de Pesquisa Energética. *Matriz Energética e Elétrica*. EPE, ABCDEnergia. Acesso em: 24 set. 2023. 2023. URL: <https://www.epe.gov.br/pt/abcdenergia/matriz-energetica-e-eletrica>.
- [2] Ministério de Minas e Energia. *Anuário Estatístico de Energia Elétrica 2023: Ano Base 2022*. Acesso em: 24 set. 2023. Rio de Janeiro: Empresa de Pesquisa Energética, 2023. URL: [https://dashboard.epe.gov.br/apps/anuario-livro/#23_Gera%C3%A7%C3%A3o_el%C3%A9trica_por_fonte_\(GWh\)](https://dashboard.epe.gov.br/apps/anuario-livro/#23_Gera%C3%A7%C3%A3o_el%C3%A9trica_por_fonte_(GWh)).
- [3] ZANELLA. “A dinâmica geoeconômica da cadeia de energia eólica no Brasil”. Tese de Doutorado. Francisco Beltrão: Universidade Estadual do Oeste do Paraná, 2021, p. 255.
- [4] Brasil ONU. *Objetivo 7: Energia Acessível e Limpa*. URL: <https://brasil.un.org/pt-br/sdgs/7> (acesso em 09/01/2024).
- [5] Jamil Ramsi Farkat et al. DIÓGENES. “Overcoming barriers to onshore wind farm implementation in Brazil”. Em: *Energy Policy* 138 (2020). Acesso em: 26 set. 2023, p. 111165. DOI: 10.1016/j.enpol.2019.111165. URL: https://www.sciencedirect.com/science/article/pii/S0301421519307517?casa_token=nJi-77YQeewAAAAA:3n_kYV1t3W9AshXJrQI91AuEx4Y4mX0MjPj0XDww4HETfj8EX94PjJiCACDcXSRXGaCRSgiltm0.
- [6] M Pessanha, AC Melo e VA Almeida. “CONSIDERAÇÃO DAS CORRELAÇÕES ESPACIAIS ENTRE OS REGIMES DE VENTOS NA GERAÇÃO DE CENÁRIOS DE PRODUÇÃO DE ENERGIA EÓLICA–APLICAÇÃO AO FLUXO DE POTÊNCIA PROBABILÍSTICO”. Em: *Cadernos do IME–Série Estatística* 52 (2022), pp. 34–53.
- [7] Mingjian et al. CUI. “Wind power ramp event forecasting using a stochastic scenario generation method”. Em: *IEEE Transactions on Sustainable Energy* 6.2 (2015). Acesso em: 25 set. 2023, pp. 422–433. URL: <https://ieeexplore.ieee.org/abstract/document/7018976>.
- [8] OPERADOR DO SISTEMA ELÉTRICO NACIONAL. *Análise da Perturbação do dia 15/08/2023 às 08h30min envolvendo o SIN*. Relatório de Análise de Perturbação. Acesso em: 28 set. 2023. Rio de Janeiro, 2023. URL: <https://www.ons.org.br/AcervoDigitalDocumentosEPublicacoes/Minuta%20do%20RAP%202023.08.15.pdf>.
- [9] Juan M. c. MORALES. *Integrating Renewables in Electricity Markets: Operational Problems*. Nova York: Springer, 2014, p. 429.

- [10] Paulo Henrique et al. CUNHA. “Análise de Rampas de Geração Fotovoltaica de Grande Escala”. Em: *Anais do 9º Simpósio Brasileiro de Sistemas Elétricos*. Acesso em: 04 ago. 2023. Santa Maria: Sociedade Brasileira de Automática, 2023, pp. 64–71. URL: https://www.sba.org.br/open_journal_systems/index.php/sbse/article/view/2886/2416.
- [11] J. Heckenbergerova, P. Musilek e J. Marek. “Análise das séries temporais de velocidade e potência do do vento que precedem eventos de rampa de vento”. Em: *Conferência Científica Internacional de Engenharia de Energia Elétrica (EPE)*. Vol. 15. 2014, pp. 279–283.
- [12] Yuzhong Gong, C. Y. Chung e R. S. Mall. “Power System Operational Adequacy Evaluation With Wind Power Ramp Limits”. Em: *IEEE Transactions on Power Systems* 33.3 (2018), pp. 2706–2716. DOI: 10.1109/TPWRS.2017.2764420.
- [13] Oliver Kramer, Nils André Treiber e Michael Sonnenschein. “Wind power ramp event prediction with support vector machines”. Em: *Hybrid Artificial Intelligence Systems: 9th International Conference, HAIS 2014, Salamanca, Spain, June 11-13, 2014. Proceedings 9*. Springer. 2014, pp. 37–48.
- [14] Karla Pereyra-Castro et al. “Wind and wind power ramp variability over Northern Mexico”. Em: *Atmosphere* 11.12 (2020), p. 1281.
- [15] H.d. N. Camelo et al. “Métodos de previsão de séries temporais e modelagem híbrida ambos aplicados em médias mensais de velocidade do vento para regiões do nordeste do brasil”. Em: *Revista Brasileira de Meteorologia* 32.4 (2017), pp. 565–574.
- [16] Q. Chen et al. “Previsões de velocidade do vento de curto prazo em várias etapas empregando fusão de recursos de resolução múltipla e mineração de informações de frequência”. Em: *Renewable Energy* 215 ().
- [17] T. M. Barchi. *Redes neurais artificiais e modelos de combinação para previsão de velocidade do vento*. 2022. URL: <http://riut.utfpr.edu.br/jspui/handle/1/30180> (acesso em 18/08/2023).
- [18] Sérgio Reinaldo Marteletto. “Técnicas de seleção de atributos através de Random Forests: um estudo de caso para detecção de tendências em séries temporais financeiras”. Tese de dout. Universidade de São Paulo, 2022.
- [19] J. C. CRUZ et al. “Estado da Arte para Previsão de Eventos de Rampas Eólicas no Sistema de Energia”. Em: *CONGRESSO BRASILEIRO DE AUTOMÁTICA, 24*. Sociedade Brasileira de Automática. Fortaleza, 2022. URL: https://www.sba.org.br/cba2022/wp-content/uploads/artigos_cba2022/paper_3569.pdf (acesso em 10/08/2023).

- [20] Lijuan Li et al. "Wind Power Ramp Events Prediction Considering Time-frequency Characteristics". Em: *2020 International Conference on Electrical Engineering (ICEE)*. 2020, pp. 1–6. DOI: 10.1109/ICEE49691.2020.9249889.
- [21] A. C. Castro Neto et al. "Controle de Rampas em Parques Eólicos". Em: *Anais do Congresso Brasileiro de Automática*. São Paulo: SBA, 2023, pp. 1–6.
- [22] R. Ferreira Filho et al. "Controle Coordenado de Parques Eólicos Usando Algoritmos de Consenso". Em: *Anais do Simpósio Brasileiro de Sistemas Elétricos*. Belém: UFPA, 2023, pp. 1–6.
- [23] R. La Bruyere et al. "Controle Preditivo de Parques Eólicos Distribuídos". Em: *IEEE Transactions on Power Systems* 38.1 (2023), pp. 12–21.
- [24] Tinghui Ouyang et al. "Prediction of wind power ramp events based on residual correction". Em: *Renewable energy* 136 (2019), pp. 781–792.
- [25] Jullya de Oliveira Clemente. "Previsão de Rampas em Séries Temporais de Potência de Saída de Centrais Eólicas". Tese de dout. Universidade Federal de Pernambuco, 2018. URL: <https://attena.ufpe.br/bitstream/123456789/33536/1/DISSERTA%C3%87%C3%83%20Jullya%20de%20oliveira%20Clemente.pdf>.
- [26] Tang Zhenhao et al. "Prediction of wind power ramp events based on deep neural network". Em: *2019 Chinese Automation Congress (CAC)*. IEEE. 2019, pp. 2081–2084.
- [27] Saurav Gupta et al. "Wind ramp event prediction with parallelized gradient boosted regression trees". Em: *2016 International Joint Conference on Neural Networks (IJCNN)*. IEEE. 2016, pp. 5296–5301.
- [28] Laura Cornejo-Bueno et al. "Wind power ramp events prediction with hybrid machine learning regression techniques and reanalysis data". Em: *Energies* 10.11 (2017), p. 1784.
- [29] Li Han et al. "Wind Power Ramp Event Forecasting Based on Feature Extraction and Deep Learning". Em: *Energies* 13.24 (2020), p. 6449.
- [30] Xiaomei Chen, Jie Zhao e Miao He. "Regional Wind Power Ramp Forecasting through Multinomial Logistic Regression". Em: *2020 IEEE Green Technologies Conference (GreenTech)*. 2020, pp. 36–41. DOI: 10.1109/GreenTech46478.2020.9289816.
- [31] C. Gallego-Castillo, A. Cuerva-Tejero e O. Lopez-Garcia. "A review on the recent history of wind power ramp forecasting". Em: *Renewable Sustainable Energy Reviews* 52 (2015), pp. 1148–1157. DOI: 10.1016/J.RSER.2015.07.154.
- [32] C. Gallego. "Statistical models for short-term wind power ramp forecasting". Tese de dout. Universidad Politécnica de Madrid, 2013.

- [33] Tinghui Ouyang, Xiaoming Zha e Liang Qin. "A Survey of Wind Power Ramp Forecasting". Em: *Energy and Power Engineering* 5.4 (2013), pp. 368–372.
- [34] Leo Breiman. "Random forests". Em: *Machine Learning* 45.1 (2001), pp. 5–32.
- [35] HASHTAG TREINAMENTOS. *Árvore de Decisão: O que é e como aplicar na Ciência de Dados*. <https://www.hashtagtreinamentos.com/arvore-decisao-ciencia-dados>. Acessado em 08 de janeiro de 2024. 2019. (Acesso em 08/01/2024).
- [36] T. Hastie, R. Tibshirani e J. Friedman. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer, 2009.
- [37] E. M. T. Souza et al. *Inteligência Artificial: Algoritmos e Aplicações*. 3ª ed. Elsevier, 2013.
- [38] J. Han, M. Kamber e J. Pei. *Data Mining: Concepts and Techniques*. 3ª ed. Elsevier, 2011.
- [39] Martin Calasan, Shady HE Abdel Aleem e Ahmed F Zobaa. "On the root mean square error (RMSE) calculation for parameter estimation of photovoltaic models: A novel exact analytical solution based on Lambert W function". Em: *Energy conversion and management* 210 (2020), p. 112716.
- [40] Wenqing Xu, Like Ning e Yong Luo. "Wind speed forecast based on post-processing of numerical weather predictions using a gradient boosting decision tree algorithm". Em: *Atmosphere* 11.7 (2020), p. 738.
- [41] S. Turney. *Coefficient of Determination (R^2) | Calculation & Interpretation*. Scribbr. Accessed: 09 Out 2023. Jun. de 2023. URL: <https://www.scribbr.com/statistics/coefficient-of-determination/>.
- [42] Arnaud de Myttenaere et al. "Regression models with MAPE as a quality measure: a new perspective". Em: *Neurocomputing* 192 (2016), pp. 38–48.
- [43] Tom Fawcett. "An introduction to ROC analysis". Em: *Pattern recognition letters* 27.8 (2006), pp. 861–874.
- [44] Stephen V Stehman. "Selecting and interpreting measures of thematic classification accuracy". Em: *Remote sensing of Environment* 62.1 (1997), pp. 77–89.
- [45] Nathalie Japkowicz e Mohak Shah. *Evaluating learning algorithms: a classification perspective*. Cambridge University Press, 2011.
- [46] David MW Powers. "Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation". Em: *arXiv preprint arXiv:2010.16061* (2020).
- [47] INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. *IBGE Cidades 2022: Paulino Neves MA*. Accessed: 09 Jan 2024. 2022. URL: <https://cidades.ibge.gov.br/brasil/ma/paulino-neves/panorama>.

- [48] COMPANHIA DE PESQUISA DE RECURSOS MINERAIS. *Relatório Diagnóstico do Município de Paulino Neves*. Accessed: 09 Jan 2024. 2011. URL: https://rigeo.cprm.gov.br/jspui/bitstream/doc/15555/1/rel-paulino_neves.pdf.
- [49] Mário Adelmo VAREJÃO-SILVA. "Meteorologia e climatologia: versão digital 2". Em: *Recife: Esalq* (2006), p. 449.
- [50] José Auricélio Gois LIMA. *A natureza contraditória da geração de energia eólica no Nordeste do Brasil*. Editora da UECE, 2022, p. 469.
- [51] Vaisala. *WindCube Siting Recommendations*. PDF. Acesso em: 15 out. 2023. 2022. URL: <https://www.vaisala.com/sites/default/files/documents/WindCube-Siting-Recommendations-DID65656EN-C.pdf>.
- [52] Movimento Lidar. *Perfilador Lidar*. 2019. URL: <https://movlidar.paginas.ufsc.br/perfilador-lidar/> (acesso em 08/01/2024).
- [53] Inc. Campbell Scientific. *TE525-Series Tipping Bucket Rain Gage Manual*. Revision: 01/2022. 2022. URL: [link%20to%20the%20PDF%20file](#).
- [54] Eduardo Braz Rabello. "Cross Validation: Avaliando seu modelo de Machine Learning". Em: *Medium* (2019). URL: <https://medium.com/@edubrazrabello/cross-validation-avaliando-seu-modelo-de-machine-learning-1fb70df15b78> (acesso em 06/09/2023).
- [55] Thiago do Nascimento Oliveira. "Construção e classificação de uma base textual em português". Em: (2023).
- [56] J. J. Andrade et al. "Prediction of the performance of bituminous mixes using adaptive neuro-fuzzy inference systems". Em: *Revista Mundi Engenharia, Tecnologia e Gestão* 5 (ago. de 2020). ISSN: 2525-4782. DOI: 10.21575/25254782rmetg2020vol5n61367.
- [57] F. M. Pimenta et al. "Characterization of wind resources of the east coast of maranhão, brazil". Em: *Energies* 16.14 (2023), p. 5555. DOI: 10.3390/en16145555.

Apêndices

APÊNDICE A – Tabelas de Métricas de Regressão.

Tabela 15 – Métricas de regressão para diferentes alturas e tempo no ponto P0

Altura	Tempo 10 (min)			Tempo 20 (min)			Tempo 30 (min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
40	0,489	0,94	4,40	0,574	0,92	5,13	0,607	0,91	5,50
50	0,417	0,96	3,55	0,480	0,94	4,05	0,505	0,94	4,34
60	0,373	0,97	3,09	0,436	0,95	3,54	0,458	0,95	3,80
70	0,335	0,97	2,75	0,393	0,96	3,14	0,414	0,96	3,33
80	0,314	0,98	2,49	0,372	0,97	2,87	0,383	0,96	2,99
90	0,296	0,98	2,28	0,346	0,97	2,61	0,360	0,97	2,77
100	0,283	0,98	2,12	0,329	0,97	2,44	0,341	0,97	2,57
110	0,265	0,98	1,97	0,313	0,97	2,34	0,323	0,97	2,37
120	0,250	0,98	1,85	0,299	0,98	2,16	0,302	0,98	2,21
130	0,240	0,98	1,76	0,286	0,98	2,07	0,301	0,98	2,16
140	0,238	0,98	1,69	0,276	0,98	1,96	0,282	0,98	1,99
150	0,232	0,99	1,66	0,266	0,98	1,90	0,280	0,98	1,94
160	0,234	0,98	1,63	0,270	0,98	1,86	0,278	0,98	1,91
170	0,235	0,98	1,62	0,271	0,98	1,85	0,278	0,98	1,90
180	0,243	0,98	1,67	0,277	0,98	1,88	0,279	0,98	1,92
190	0,251	0,98	1,73	0,289	0,97	1,94	0,295	0,97	2,02
200	0,273	0,98	1,89	0,311	0,97	2,13	0,323	0,97	2,22
220	0,304	0,97	2,15	0,354	0,96	2,44	0,369	0,96	2,52
240	0,326	0,97	2,36	0,380	0,95	2,69	0,399	0,95	2,78
260	0,382	0,95	2,76	0,446	0,94	3,15	0,478	0,93	3,41
Altura	Tempo 40 (min)			Tempo 50 (min)			Tempo 60 (min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
40	0,634	0,90	5,82	0,639	0,90	5,89	0,650	0,89	6,09
50	0,518	0,93	4,47	0,524	0,93	4,55	0,518	0,93	4,54
60	0,455	0,95	3,78	0,459	0,95	3,86	0,457	0,95	3,95
70	0,414	0,96	3,35	0,409	0,96	3,41	0,411	0,96	3,46
80	0,385	0,96	3,09	0,379	0,96	3,14	0,381	0,96	3,18
90	0,358	0,97	2,84	0,357	0,97	2,91	0,362	0,97	2,86
100	0,331	0,97	2,63	0,341	0,97	2,66	0,341	0,97	2,65
110	0,321	0,97	2,50	0,327	0,97	2,48	0,332	0,97	2,52
120	0,309	0,98	2,37	0,311	0,97	2,36	0,319	0,97	2,42
130	0,296	0,98	2,22	0,296	0,98	2,21	0,298	0,98	2,15
140	0,274	0,98	2,04	0,286	0,98	2,07	0,288	0,98	2,05
150	0,274	0,98	1,98	0,278	0,98	1,99	0,281	0,98	1,99
160	0,271	0,98	1,97	0,267	0,98	1,91	0,270	0,98	1,91
170	0,271	0,98	1,91	0,274	0,98	1,92	0,274	0,98	1,91
180	0,276	0,98	1,94	0,276	0,98	1,94	0,278	0,98	1,94
190	0,293	0,97	2,06	0,285	0,98	2,00	0,291	0,97	2,03
200	0,316	0,97	2,25	0,303	0,97	2,19	0,313	0,97	2,20
220	0,356	0,96	2,54	0,357	0,96	2,54	0,363	0,96	2,56
240	0,394	0,95	2,81	0,395	0,95	2,86	0,404	0,95	2,89
260	0,479	0,93	3,41	0,476	0,93	3,42	0,491	0,92	3,49

Tabela 16 – Métricas de regressão para diferentes alturas e tempo no ponto P1

Altura	Tempo 10 (min)			Tempo 20 (min)			Tempo 30 (min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
40	0,5705	0,880	5,49	0,6403	0,848	6,17	0,6758	0,831	6,51
50	0,5403	0,891	4,95	0,6012	0,865	5,51	0,6265	0,854	5,74
60	0,5298	0,894	4,68	0,5882	0,870	5,18	0,6059	0,862	5,36
70	0,5167	0,899	4,43	0,5691	0,878	4,84	0,5875	0,870	5,03
80	0,5017	0,905	4,17	0,5488	0,887	4,54	0,5632	0,881	4,70
90	0,4889	0,910	3,97	0,5345	0,893	4,32	0,5489	0,887	4,45
100	0,4827	0,913	3,85	0,5281	0,896	4,17	0,5412	0,891	4,29
110	0,4656	0,920	3,63	0,5047	0,906	3,90	0,5188	0,901	4,04
120	0,4480	0,927	3,43	0,4827	0,915	3,68	0,4990	0,909	3,79
130	0,4370	0,931	3,30	0,4707	0,920	3,51	0,4827	0,916	3,61
140	0,4194	0,938	3,14	0,4534	0,927	3,35	0,4616	0,924	3,41
150	0,4063	0,942	3,00	0,4362	0,933	3,19	0,4443	0,931	3,24
160	0,3908	0,947	2,87	0,4220	0,938	3,04	0,4231	0,938	3,06
170	0,3783	0,951	2,76	0,4085	0,943	2,93	0,4085	0,943	2,94
180	0,3732	0,953	2,72	0,3970	0,947	2,86	0,4041	0,945	2,89
190	0,3723	0,954	2,70	0,3989	0,947	2,86	0,4042	0,945	2,91
200	0,3900	0,950	2,84	0,4162	0,943	3,01	0,4281	0,939	3,07
220	0,4152	0,944	3,03	0,4486	0,935	3,25	0,4583	0,932	3,30
240	0,4335	0,940	3,15	0,4699	0,930	3,40	0,4815	0,926	3,48
260	0,4652	0,932	3,40	0,5227	0,915	3,79	0,5379	0,910	3,90
Altura	Tempo 40 (min)			Tempo 50 (min)			Tempo 60 (min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
40	0,6876	0,826	6,70	0,6936	0,823	6,81	0,7039	0,818	6,87
50	0,6364	0,849	5,88	0,6351	0,850	5,90	0,6378	0,849	5,91
60	0,6145	0,858	5,47	0,6128	0,859	5,49	0,6178	0,8572	5,51
70	0,5923	0,868	5,08	0,5965	0,866	5,17	0,5974	0,866	5,15
80	0,5703	0,878	4,76	0,5719	0,877	4,79	0,5741	0,8764	4,81
90	0,5587	0,883	4,54	0,5578	0,884	4,57	0,5558	0,8846	4,55
100	0,5454	0,890	4,33	0,5487	0,888	4,37	0,5478	0,8887	4,38
110	0,5198	0,901	4,03	0,5195	0,901	4,05	0,5232	0,8994	4,10
120	0,4963	0,910	3,77	0,4951	0,911	3,80	0,4915	0,9122	3,79
130	0,4810	0,917	3,58	0,4769	0,918	3,59	0,4711	0,9204	3,57
140	0,4596	0,925	3,39	0,4593	0,925	3,40	0,4532	0,9273	3,38
150	0,4366	0,933	3,20	0,4382	0,933	3,22	0,4345	0,934	3,20
160	0,4241	0,938	3,05	0,4240	0,938	3,06	0,4191	0,9393	3,04
170	0,4119	0,942	2,94	0,4086	0,943	2,94	0,4003	0,9453	2,91
180	0,4012	0,946	2,88	0,3958	0,947	2,85	0,3936	0,9477	2,85
190	0,4071	0,945	2,90	0,3988	0,947	2,87	0,3940	0,9481	2,86
200	0,4258	0,940	3,06	0,4192	0,942	3,03	0,4139	0,9434	3,02
220	0,4614	0,931	3,34	0,4533	0,933	3,31	0,4528	0,9335	3,32
240	0,4827	0,926	3,51	0,4799	0,927	3,52	0,4858	0,925	3,54
260	0,5430	0,908	3,96	0,5407	0,909	3,97	0,5518	0,9051	4,02

Tabela 17 – Métricas de regressão para diferentes alturas e tempo no ponto P2

Altura	Tempo 10 (min)			Tempo 20 (min)			Tempo 30 (min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
40	0,5698	0,95	7,8	0,6773	0,929	9,75	0,7143	0,922	10,53
50	0,5188	0,959	6,72	0,6044	0,945	8,13	0,6289	0,94	8,67
60	0,4932	0,963	6,08	0,5676	0,952	7,27	0,5891	0,948	7,79
70	0,4719	0,967	5,67	0,5377	0,957	6,7	0,5534	0,954	7,03
80	0,4564	0,969	5,36	0,519	0,96	6,28	0,534	0,957	6,55
90	0,4405	0,971	5,04	0,5077	0,961	5,99	0,5143	0,96	6,17
100	0,4307	0,972	4,87	0,4958	0,963	5,74	0,4982	0,963	5,87
110	0,4238	0,973	4,71	0,4861	0,964	5,57	0,4887	0,964	5,71
120	0,4193	0,973	4,59	0,4725	0,966	5,3	0,4711	0,966	5,45
130	0,4092	0,975	4,39	0,4593	0,968	5,07	0,4625	0,967	5,24
140	0,3956	0,976	4,25	0,4504	0,969	4,89	0,4487	0,969	5,06
150	0,3926	0,976	4,2	0,4408	0,97	4,79	0,4429	0,97	4,99
160	0,3843	0,977	4,14	0,4346	0,971	4,68	0,4373	0,97	4,96
170	0,3823	0,977	4,15	0,4342	0,971	4,81	0,4382	0,97	5,09
180	0,3807	0,977	3,95	0,4381	0,97	4,6	0,4381	0,97	4,79
190	0,386	0,977	3,86	0,4551	0,967	4,55	0,4564	0,967	4,74
200	0,4054	0,974	4,04	0,4746	0,964	4,76	0,4852	0,963	4,98
220	0,4414	0,969	4,42	0,5224	0,956	5,18	0,5327	0,955	5,43
240	0,468	0,965	4,63	0,5472	0,952	5,4	0,5683	0,948	5,72
260	0,5107	0,958	4,97	0,6051	0,941	5,96	0,64	0,934	6,41
Altura	Tempo 40 (min)			Tempo 50 (min)			Tempo 60 (min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
40	0,7258	0,919	11,01	0,7315	0,918	11,36	0,7464	0,915	11,68
50	0,6367	0,939	9,06	0,63	0,94	9,16	0,6382	0,938	9,32
60	0,5854	0,949	7,95	0,5873	0,948	8,15	0,5921	0,947	8,2
70	0,558	0,953	7,34	0,5549	0,954	7,35	0,5582	0,953	7,41
80	0,5355	0,957	6,7	0,53	0,958	6,7	0,536	0,957	6,77
90	0,5112	0,961	6,23	0,5059	0,962	6,19	0,5061	0,962	6,25
100	0,4958	0,963	5,9	0,4928	0,963	5,93	0,4948	0,963	5,92
110	0,4905	0,964	5,82	0,4784	0,965	5,73	0,4862	0,964	5,78
120	0,4817	0,965	5,57	0,4648	0,967	5,5	0,4705	0,966	5,51
130	0,467	0,967	5,32	0,4586	0,968	5,33	0,4668	0,967	5,38
140	0,4584	0,968	5,13	0,4456	0,97	5,15	0,4553	0,968	5,21
150	0,4443	0,97	5,05	0,4389	0,97	5,02	0,4462	0,969	5,09
160	0,4401	0,97	5,02	0,4315	0,971	5,02	0,4375	0,97	5,11
170	0,4334	0,971	5,09	0,4272	0,972	5	0,4322	0,971	5,15
180	0,436	0,97	4,78	0,4236	0,972	4,7	0,4321	0,971	4,89
190	0,4509	0,968	4,77	0,4322	0,971	4,62	0,4395	0,97	4,69
200	0,4811	0,963	4,97	0,4696	0,965	4,87	0,4705	0,965	4,95
220	0,539	0,954	5,54	0,5295	0,955	5,44	0,5206	0,957	5,47
240	0,5827	0,946	5,94	0,5549	0,951	5,72	0,5659	0,949	5,89
260	0,6527	0,931	6,62	0,6436	0,933	6,6	0,6558	0,931	6,71

Tabela 18 – Métricas de regressão para diferentes alturas e tempo no ponto P6

Altura	Tempo 10 (min)			Tempo 20 (min)			Tempo 30 (min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
40	0,5129	0,924	5,49	0,5941	0,898	6,51	0,6401	0,882	7,12
50	0,4634	0,935	4,8	0,5281	0,916	5,56	0,5694	0,903	6,05
60	0,451	0,937	4,49	0,5085	0,919	5,12	0,5454	0,907	5,53
70	0,4376	0,938	4,2	0,4955	0,921	4,79	0,5292	0,91	5,18
80	0,4263	0,94	3,94	0,48	0,924	4,48	0,5122	0,914	4,8
90	0,419	0,942	3,75	0,4692	0,927	4,23	0,4989	0,917	4,54
100	0,4105	0,944	3,59	0,4665	0,927	4,12	0,4915	0,919	4,35
110	0,4071	0,945	3,48	0,4595	0,93	3,97	0,4835	0,922	4,17
120	0,4061	0,946	3,42	0,452	0,932	3,82	0,4742	0,926	4,02
130	0,3976	0,948	3,29	0,4413	0,937	3,66	0,4621	0,93	3,82
140	0,3893	0,951	3,2	0,4341	0,94	3,54	0,4501	0,935	3,69
150	0,3836	0,954	3,12	0,4298	0,942	3,48	0,4448	0,938	3,62
160	0,3793	0,956	3,05	0,4204	0,946	3,37	0,4375	0,941	3,51
170	0,3688	0,959	2,95	0,4071	0,95	3,25	0,42	0,947	3,37
180	0,3641	0,961	2,92	0,4066	0,952	3,23	0,4196	0,949	3,34
190	0,3646	0,962	2,93	0,4078	0,953	3,25	0,4224	0,95	3,36
200	0,3815	0,96	3,09	0,431	0,949	3,42	0,4459	0,945	3,54
220	0,4079	0,957	3,32	0,4667	0,943	3,72	0,4832	0,939	3,88
240	0,4214	0,957	3,43	0,4794	0,944	3,87	0,5028	0,938	4,09
260	0,4545	0,952	3,75	0,5312	0,935	4,3	0,5628	0,927	4,64
Altura	Tempo 40 (min)			Tempo 50 (min)			Tempo 60 (min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
40	0,6706	0,871	7,52	0,6951	0,861	7,94	0,7045	0,857	8,06
50	0,586	0,897	6,23	0,6059	0,89	6,51	0,6073	0,889	6,54
60	0,5563	0,903	5,67	0,5734	0,897	5,87	0,5762	0,896	5,93
70	0,5395	0,906	5,26	0,5515	0,902	5,39	0,5581	0,9	5,47
80	0,5214	0,911	4,89	0,5328	0,907	5,03	0,537	0,905	5,06
90	0,506	0,915	4,61	0,5219	0,909	4,78	0,5229	0,909	4,78
100	0,5037	0,915	4,45	0,5167	0,911	4,6	0,5131	0,912	4,57
110	0,4965	0,918	4,3	0,505	0,915	4,41	0,5072	0,914	4,39
120	0,48	0,924	4,09	0,4917	0,92	4,19	0,4929	0,92	4,19
130	0,4701	0,928	3,93	0,4819	0,924	4	0,4835	0,924	4,01
140	0,4637	0,931	3,81	0,4726	0,928	3,87	0,4762	0,927	3,88
150	0,4553	0,935	3,69	0,469	0,931	3,78	0,4702	0,931	3,79
160	0,4409	0,94	3,55	0,4582	0,936	3,67	0,4585	0,936	3,66
170	0,4275	0,945	3,42	0,4419	0,942	3,52	0,4469	0,94	3,54
180	0,4217	0,948	3,36	0,4338	0,945	3,43	0,4418	0,943	3,48
190	0,4287	0,948	3,41	0,4348	0,946	3,44	0,4485	0,943	3,53
200	0,4532	0,944	3,6	0,4605	0,942	3,63	0,4689	0,94	3,7
220	0,491	0,937	3,93	0,5022	0,934	4,01	0,5137	0,931	4,11
240	0,5135	0,936	4,16	0,5212	0,934	4,26	0,5389	0,929	4,36
260	0,5757	0,924	4,77	0,5905	0,92	4,9	0,6087	0,915	5,05

Tabela 19 – Métricas de regressão para diferentes alturas e tempo no ponto P7

Altura	Tempo 10 (min)			Tempo 20 (min)			Tempo 30 (min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
40	0,569	0,926	4,97	0,632	0,909	5,52	0,652	0,904	5,7
50	0,5275	0,937	4,39	0,5782	0,925	4,82	0,5925	0,921	4,9
60	0,5033	0,943	4,04	0,5473	0,933	4,39	0,56	0,93	4,46
70	0,4776	0,949	3,73	0,5191	0,94	4,05	0,5296	0,938	4,1
80	0,4569	0,954	3,49	0,4943	0,946	3,76	0,5025	0,944	3,78
90	0,4397	0,957	3,3	0,4735	0,951	3,51	0,4837	0,949	3,56
100	0,4217	0,961	3,1	0,4566	0,955	3,33	0,4599	0,954	3,36
110	0,4042	0,965	2,93	0,4304	0,96	3,1	0,437	0,959	3,15
120	0,3881	0,968	2,78	0,4154	0,963	2,96	0,4171	0,963	2,96
130	0,3769	0,97	2,67	0,3982	0,966	2,83	0,4019	0,966	2,83
140	0,3665	0,972	2,6	0,3883	0,968	2,74	0,3892	0,968	2,74
150	0,3546	0,974	2,52	0,3772	0,97	2,67	0,3817	0,97	2,7
160	0,3463	0,975	2,44	0,3669	0,972	2,58	0,3716	0,971	2,6
170	0,3403	0,976	2,39	0,3569	0,974	2,51	0,3628	0,973	2,54
180	0,3373	0,977	2,37	0,3533	0,975	2,49	0,3602	0,974	2,53
190	0,3413	0,976	2,41	0,3598	0,974	2,56	0,364	0,973	2,58
200	0,3599	0,974	2,55	0,3835	0,97	2,71	0,3855	0,97	2,73
220	0,3906	0,97	2,78	0,4203	0,965	2,98	0,4231	0,965	3,02
240	0,4079	0,967	2,93	0,4444	0,961	3,17	0,4502	0,96	3,25
260	0,4509	0,96	3,24	0,4963	0,952	3,58	0,5113	0,949	3,69
Altura	Tempo 40 (min)			Tempo 50 (min)			Tempo 60 (min)		
	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE
40	0,6687	0,899	5,88	0,676	0,897	5,98	0,6825	0,895	6,05
50	0,6032	0,919	4,99	0,6043	0,918	5,03	0,604	0,919	5,05
60	0,5671	0,929	4,53	0,5696	0,928	4,56	0,5704	0,928	4,58
70	0,5369	0,936	4,17	0,5384	0,936	4,18	0,5394	0,936	4,2
80	0,5062	0,944	3,84	0,5082	0,943	3,86	0,511	0,943	3,89
90	0,4896	0,948	3,64	0,491	0,947	3,68	0,4897	0,948	3,67
100	0,4706	0,952	3,43	0,4675	0,953	3,44	0,4666	0,953	3,46
110	0,4485	0,957	3,24	0,4433	0,958	3,22	0,4435	0,958	3,25
120	0,4273	0,961	3,06	0,4209	0,962	3,03	0,4265	0,961	3,1
130	0,4061	0,965	2,88	0,4033	0,966	2,89	0,4053	0,965	2,94
140	0,3928	0,968	2,79	0,3926	0,968	2,81	0,391	0,968	2,83
150	0,3847	0,969	2,72	0,383	0,97	2,75	0,3788	0,97	2,75
160	0,3743	0,971	2,65	0,3687	0,972	2,62	0,3665	0,972	2,63
170	0,3648	0,973	2,56	0,3614	0,973	2,57	0,3604	0,974	2,57
180	0,364	0,973	2,55	0,3542	0,975	2,53	0,358	0,974	2,55
190	0,3682	0,973	2,61	0,363	0,973	2,57	0,364	0,973	2,61
200	0,3919	0,969	2,76	0,3885	0,97	2,76	0,3894	0,97	2,78
220	0,4355	0,962	3,08	0,4323	0,963	3,07	0,4332	0,963	3,12
240	0,4639	0,958	3,33	0,4661	0,957	3,34	0,4679	0,957	3,43
260	0,5292	0,946	3,81	0,5323	0,945	3,86	0,5412	0,943	3,96

APÊNDICE B – Tabelas de Métricas de Classificação.

Tabela 20 – Métricas de classificação em diferentes alturas e tempo no ponto P0

Altura	Tempo 10 (min)			Tempo 20 (min)			Tempo 30 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
40	0.957	0.956	0.957	0.978	0.981	0.980	0.968	0.971	0.970
50	0.966	0.970	0.968	0.939	0.944	0.942	0.971	0.972	0.972
60	0.977	0.977	0.977	0.970	0.972	0.971	0.938	0.941	0.939
70	0.969	0.968	0.969	0.938	0.943	0.941	0.961	0.961	0.961
80	0.983	0.984	0.984	0.954	0.955	0.955	0.932	0.949	0.942
90	0.976	0.978	0.977	0.962	0.961	0.961	0.964	0.963	0.964
100	0.969	0.968	0.969	0.980	0.980	0.980	0.959	0.962	0.961
110	0.976	0.978	0.977	0.978	0.981	0.979	0.961	0.966	0.964
120	0.985	0.983	0.984	0.982	0.979	0.980	0.963	0.971	0.967
130	0.967	0.971	0.969	0.977	0.981	0.979	0.975	0.981	0.978
140	0.974	0.978	0.976	0.971	0.968	0.970	0.932	0.938	0.935
150	0.964	0.969	0.967	0.946	0.957	0.952	0.974	0.979	0.977
160	0.973	0.973	0.973	0.957	0.957	0.957	0.916	0.925	0.920
170	0.972	0.976	0.974	0.976	0.977	0.976	0.957	0.961	0.959
180	0.970	0.973	0.971	0.961	0.962	0.962	0.987	0.988	0.988
190	0.951	0.960	0.956	0.974	0.977	0.976	0.958	0.966	0.962
200	0.990	0.990	0.990	0.986	0.988	0.987	0.987	0.987	0.987
220	0.968	0.968	0.968	0.970	0.972	0.971	0.966	0.967	0.966
240	0.966	0.968	0.967	0.971	0.968	0.969	0.898	0.918	0.909
260	0.964	0.965	0.964	0.936	0.941	0.939	0.955	0.963	0.959

Altura	Tempo 40 (min)			Tempo 50 (min)			Tempo 60 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
40	0.957	0.964	0.960	0.960	0.963	0.962	0.974	0.972	0.973
50	0.967	0.972	0.970	0.956	0.957	0.957	0.941	0.945	0.943
60	0.972	0.975	0.974	0.947	0.945	0.946	0.990	0.991	0.990
70	0.942	0.944	0.943	0.966	0.974	0.971	0.980	0.982	0.981
80	0.968	0.974	0.972	0.964	0.957	0.960	0.989	0.991	0.990
90	0.935	0.929	0.932	0.952	0.954	0.953	0.971	0.972	0.972
100	0.944	0.956	0.950	0.971	0.972	0.972	0.950	0.955	0.953
110	0.939	0.944	0.942	0.978	0.980	0.979	1.000	1.000	1.000
120	0.969	0.968	0.968	1.000	1.000	1.000	0.977	0.981	0.979
130	0.976	0.979	0.978	0.966	0.975	0.971	0.957	0.957	0.957
140	0.969	0.970	0.970	0.964	0.971	0.968	0.967	0.967	0.967
150	0.943	0.948	0.946	0.989	0.989	0.989	0.950	0.962	0.957
160	0.966	0.968	0.967	0.962	0.970	0.967	0.953	0.957	0.955
170	0.974	0.980	0.978	0.963	0.966	0.964	0.974	0.977	0.976
180	0.964	0.966	0.965	0.978	0.979	0.978	1.000	1.000	1.000
190	0.972	0.973	0.973	0.965	0.963	0.964	0.970	0.976	0.973
200	0.985	0.987	0.986	0.952	0.961	0.957	0.968	0.972	0.970
220	0.962	0.964	0.963	0.938	0.933	0.935	0.964	0.971	0.968
240	0.933	0.935	0.934	0.857	0.852	0.855	0.898	0.912	0.906
260	0.894	0.884	0.889	0.906	0.902	0.904	0.920	0.931	0.926

Tabela 21 – Métricas de classificação em diferentes alturas e tempo no ponto P1

Altura	Tempo 10 (min)			Tempo 20 (min)			Tempo 30 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
40	0,994	0,994	0,994	0,983	0,983	0,983	0,988	0,991	0,990
50	0,994	0,993	0,994	0,988	0,992	0,990	0,964	0,963	0,963
60	1,000	1,000	1,000	1,000	1,000	1,000	0,960	0,967	0,964
70	1,000	1,000	1,000	1,000	1,000	1,000	0,985	0,985	0,985
80	0,992	0,993	0,993	0,989	0,989	0,989	1,000	1,000	1,000
90	0,969	0,970	0,969	0,966	0,965	0,966	0,958	0,961	0,959
100	0,993	0,992	0,992	0,987	0,988	0,988	0,973	0,971	0,972
110	1,000	1,000	1,000	0,959	0,965	0,962	0,951	0,958	0,955
120	1,000	1,000	1,000	0,985	0,985	0,985	0,970	0,971	0,971
130	0,981	0,983	0,982	0,986	0,986	0,986	0,987	0,985	0,986
140	0,975	0,974	0,975	0,986	0,985	0,985	0,982	0,984	0,983
150	1,000	1,000	1,000	0,971	0,971	0,971	0,971	0,970	0,970
160	1,000	1,000	1,000	1,000	1,000	1,000	0,985	0,984	0,984
170	0,983	0,981	0,982	0,974	0,974	0,974	0,966	0,962	0,964
180	0,991	0,991	0,991	0,961	0,957	0,959	0,962	0,963	0,962
190	0,973	0,971	0,972	0,955	0,952	0,954	0,952	0,951	0,952
200	0,972	0,971	0,972	1,000	1,000	1,000	0,945	0,949	0,947
220	0,990	0,990	0,990	0,967	0,970	0,968	0,976	0,978	0,977
240	0,957	0,952	0,955	0,929	0,926	0,927	0,909	0,909	0,909
260	0,987	0,989	0,988	0,980	0,980	0,980	0,944	0,923	0,935

Altura	Tempo 40 (min)			Tempo 50 (min)			Tempo 60 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
40	0,957	0,967	0,963	1,000	1,000	1,000	0,900	0,952	0,935
50	0,984	0,986	0,985	0,968	0,968	0,968	0,917	0,957	0,944
60	0,954	0,954	0,954	0,966	0,967	0,966	0,967	0,976	0,972
70	0,941	0,952	0,947	0,982	0,985	0,984	0,941	0,954	0,948
80	0,966	0,971	0,968	1,000	1,000	1,000	0,967	0,964	0,966
90	0,977	0,986	0,983	0,978	0,987	0,984	0,959	0,951	0,955
100	0,980	0,986	0,984	0,954	0,961	0,958	0,963	0,969	0,966
110	0,962	0,963	0,962	0,962	0,969	0,966	0,981	0,985	0,983
120	0,984	0,986	0,985	0,967	0,970	0,968	0,976	0,967	0,972
130	0,966	0,970	0,968	0,966	0,969	0,967	0,986	0,985	0,985
140	0,973	0,968	0,971	0,984	0,982	0,983	0,935	0,935	0,935
150	0,983	0,985	0,984	0,984	0,981	0,983	0,972	0,964	0,969
160	0,928	0,915	0,922	0,938	0,926	0,932	0,951	0,951	0,951
170	0,966	0,968	0,967	0,945	0,941	0,943	0,951	0,943	0,947
180	0,962	0,966	0,964	0,951	0,941	0,946	0,915	0,912	0,914
190	0,936	0,945	0,941	0,964	0,966	0,965	0,982	0,981	0,981
200	0,951	0,947	0,949	0,945	0,949	0,947	0,941	0,933	0,938
220	0,957	0,957	0,957	0,939	0,933	0,936	0,976	0,973	0,974
240	0,872	0,848	0,861	0,971	0,968	0,970	0,839	0,800	0,821
260	0,889	0,903	0,897	0,929	0,929	0,929	0,960	0,966	0,963

Tabela 22 – Métricas de classificação em diferentes alturas e tempo no ponto P2

Altura	Tempo 10 (min)			Tempo 20 (min)			Tempo 30 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
40	0,998	0,997	0,998	0,993	0,994	0,994	0,996	0,996	0,996
50	0,990	0,989	0,989	0,992	0,993	0,993	0,989	0,988	0,989
60	0,995	0,995	0,995	0,996	0,997	0,996	0,978	0,982	0,980
70	0,994	0,995	0,995	0,989	0,989	0,989	0,996	0,996	0,996
80	0,997	0,997	0,997	0,993	0,993	0,993	0,980	0,979	0,980
90	1,000	1,000	1,000	0,993	0,993	0,993	0,996	0,996	0,996
100	0,991	0,991	0,991	0,996	0,996	0,996	0,992	0,992	0,992
110	0,997	0,997	0,997	0,992	0,992	0,992	0,996	0,996	0,996
120	0,988	0,989	0,989	0,985	0,985	0,985	0,987	0,989	0,988
130	0,991	0,991	0,991	0,996	0,997	0,996	0,996	0,996	0,996
140	1,000	1,000	1,000	0,971	0,975	0,973	0,983	0,983	0,983
150	0,991	0,991	0,991	0,972	0,974	0,973	0,979	0,979	0,979
160	0,983	0,982	0,982	0,986	0,989	0,988	0,974	0,975	0,975
170	0,993	0,994	0,994	0,975	0,977	0,976	0,978	0,977	0,977
180	0,990	0,991	0,991	0,969	0,972	0,970	0,981	0,982	0,981
190	0,997	0,997	0,997	0,974	0,975	0,974	0,978	0,980	0,979
200	0,990	0,991	0,990	0,990	0,991	0,991	0,994	0,994	0,994
220	0,996	0,997	0,996	0,990	0,990	0,990	0,993	0,994	0,993
240	0,992	0,993	0,993	0,978	0,979	0,979	0,980	0,980	0,980
260	0,996	0,996	0,996	0,990	0,990	0,990	0,961	0,962	0,962

Altura	Tempo 40 (min)			Tempo 50 (min)			Tempo 60 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
40	0,993	0,993	0,993	0,985	0,985	0,985	0,996	0,997	0,997
50	1,000	1,000	1,000	0,997	0,997	0,997	1,000	1,000	1,000
60	0,989	0,989	0,989	0,993	0,994	0,993	0,996	0,997	0,996
70	0,996	0,996	0,996	0,992	0,993	0,992	1,000	1,000	1,000
80	0,996	0,997	0,996	0,996	0,996	0,996	0,990	0,990	0,990
90	0,992	0,993	0,993	0,996	0,996	0,996	0,992	0,993	0,993
100	0,996	0,996	0,996	0,996	0,996	0,996	0,996	0,996	0,996
110	0,993	0,992	0,993	0,996	0,996	0,996	0,989	0,989	0,989
120	0,985	0,984	0,985	0,988	0,989	0,989	1,000	1,000	1,000
130	1,000	1,000	1,000	0,996	0,996	0,996	0,992	0,993	0,993
140	0,983	0,984	0,983	0,992	0,992	0,992	0,980	0,981	0,981
150	0,975	0,976	0,976	0,988	0,988	0,988	0,988	0,989	0,989
160	0,987	0,988	0,987	0,996	0,996	0,996	0,987	0,988	0,988
170	0,982	0,982	0,982	0,987	0,986	0,986	0,985	0,984	0,984
180	0,981	0,981	0,981	0,996	0,995	0,995	0,991	0,991	0,991
190	1,000	1,000	1,000	0,991	0,990	0,991	0,987	0,988	0,987
200	0,980	0,977	0,979	0,995	0,994	0,995	0,995	0,995	0,995
220	0,994	0,994	0,994	0,994	0,994	0,994	0,965	0,966	0,966
240	0,971	0,974	0,973	0,983	0,980	0,982	1,000	1,000	1,000
260	0,986	0,988	0,987	0,966	0,964	0,965	0,981	0,982	0,981

Tabela 23 – Métricas de classificação em diferentes alturas e tempo no ponto P6

Altura	Tempo 10 (min)			Tempo 20 (min)			Tempo 30 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
40	1,000	1,000	1,000	0,987	0,989	0,988	1,000	1,000	1,000
50	0,991	0,991	0,991	0,976	0,977	0,977	0,993	0,994	0,993
60	0,990	0,990	0,990	0,967	0,970	0,969	0,983	0,986	0,984
70	0,977	0,984	0,981	0,981	0,980	0,980	0,991	0,992	0,991
80	0,989	0,990	0,990	0,985	0,985	0,985	0,980	0,984	0,982
90	0,984	0,985	0,985	0,992	0,992	0,992	0,989	0,991	0,990
100	0,983	0,984	0,983	0,986	0,986	0,986	0,968	0,971	0,969
110	0,989	0,989	0,989	0,968	0,971	0,969	0,967	0,971	0,969
120	0,988	0,989	0,989	0,991	0,993	0,992	0,978	0,980	0,979
130	0,995	0,995	0,995	1,000	1,000	1,000	0,974	0,983	0,979
140	0,994	0,995	0,995	0,983	0,984	0,984	0,964	0,972	0,968
150	0,984	0,983	0,984	0,992	0,992	0,992	0,978	0,980	0,979
160	0,994	0,995	0,995	1,000	1,000	1,000	0,940	0,947	0,944
170	0,982	0,985	0,984	0,992	0,992	0,992	0,980	0,980	0,980
180	1,000	1,000	1,000	0,982	0,984	0,983	0,967	0,968	0,967
190	0,987	0,989	0,988	1,000	1,000	1,000	0,966	0,969	0,967
200	0,994	0,994	0,994	0,990	0,991	0,991	0,944	0,960	0,953
220	0,986	0,989	0,987	1,000	1,000	1,000	0,985	0,990	0,988
240	0,993	0,994	0,993	0,981	0,978	0,980	0,951	0,951	0,951
260	1,000	1,000	1,000	0,990	0,990	0,990	0,947	0,952	0,950

Altura	Tempo 40 (min)			Tempo 50 (min)			Tempo 60 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
40	0,983	0,986	0,985	0,985	0,987	0,986	0,967	0,969	0,968
50	0,991	0,993	0,992	0,968	0,969	0,968	0,976	0,972	0,974
60	0,978	0,985	0,982	0,966	0,965	0,965	0,937	0,967	0,957
70	0,958	0,963	0,961	1,000	1,000	1,000	1,000	1,000	1,000
80	0,946	0,955	0,951	0,938	0,936	0,937	0,949	0,970	0,962
90	0,978	0,979	0,978	0,951	0,957	0,955	0,962	0,973	0,968
100	0,965	0,966	0,965	0,938	0,959	0,951	0,966	0,973	0,970
110	0,933	0,933	0,933	0,944	0,938	0,941	0,933	0,956	0,947
120	0,978	0,980	0,979	0,921	0,940	0,932	0,899	0,933	0,920
130	0,990	0,989	0,990	0,958	0,966	0,962	0,975	0,979	0,977
140	0,968	0,970	0,969	0,919	0,939	0,930	0,959	0,968	0,964
150	0,947	0,958	0,953	1,000	1,000	1,000	1,000	1,000	1,000
160	0,977	0,980	0,978	0,988	0,989	0,988	0,966	0,970	0,968
170	0,951	0,960	0,956	1,000	1,000	1,000	0,974	0,974	0,974
180	0,956	0,960	0,958	0,989	0,989	0,989	0,951	0,953	0,952
190	0,956	0,951	0,953	0,976	0,968	0,973	0,949	0,957	0,953
200	0,921	0,932	0,927	1,000	1,000	1,000	0,974	0,976	0,975
220	0,960	0,970	0,966	1,000	1,000	1,000	0,957	0,959	0,958
240	0,971	0,973	0,972	0,943	0,952	0,948	0,923	0,925	0,924
260	0,944	0,935	0,940	0,981	0,982	0,981	0,938	0,938	0,938

Tabela 24 – Métricas de classificação em diferentes alturas e tempo no ponto P7

Altura	Tempo 10 (min)			Tempo 20 (min)			Tempo 30 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
40	0,982	0,988	0,986	0,967	0,972	0,970	0,971	0,977	0,974
50	0,956	0,958	0,957	0,907	0,915	0,911	0,938	0,944	0,941
60	0,986	0,986	0,986	0,969	0,965	0,967	0,950	0,951	0,951
70	0,957	0,952	0,954	0,952	0,958	0,956	0,841	0,864	0,853
80	0,947	0,952	0,950	0,935	0,948	0,943	0,957	0,959	0,958
90	0,969	0,971	0,970	0,963	0,962	0,963	0,945	0,959	0,953
100	0,974	0,977	0,976	0,911	0,925	0,919	0,951	0,955	0,953
110	0,983	0,984	0,984	0,978	0,977	0,978	0,864	0,927	0,905
120	0,985	0,983	0,984	0,975	0,974	0,974	0,918	0,918	0,918
130	1,000	1,000	1,000	0,921	0,927	0,924	0,963	0,963	0,963
140	0,984	0,982	0,983	0,958	0,968	0,963	0,912	0,897	0,905
150	0,981	0,984	0,983	0,928	0,933	0,931	0,929	0,950	0,941
160	0,958	0,957	0,957	0,969	0,973	0,971	0,833	0,839	0,836
170	0,973	0,976	0,975	0,974	0,974	0,974	0,955	0,947	0,952
180	0,982	0,981	0,982	0,862	0,877	0,870	0,933	0,945	0,940
190	0,932	0,938	0,935	0,909	0,938	0,926	0,868	0,889	0,879
200	0,952	0,957	0,955	0,930	0,921	0,925	0,824	0,885	0,860
220	0,948	0,952	0,950	0,923	0,918	0,921	0,839	0,865	0,853
240	0,966	0,966	0,966	0,826	0,846	0,837	0,875	0,875	0,875
260	0,959	0,961	0,960	0,837	0,873	0,857	0,769	0,842	0,813

Altura	Tempo 40 (min)			Tempo 50 (min)			Tempo 60 (min)		
	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia	F1SC	F1SD	Acurácia
40	0,923	0,941	0,933	0,873	0,931	0,910	0,766	0,882	0,843
50	0,912	0,943	0,931	0,851	0,920	0,896	0,885	0,929	0,912
60	0,901	0,925	0,915	0,918	0,925	0,922	0,928	0,937	0,932
70	0,943	0,966	0,957	0,884	0,941	0,922	0,902	0,925	0,915
80	0,885	0,892	0,889	0,889	0,927	0,912	0,851	0,920	0,896
90	0,865	0,923	0,902	0,857	0,857	0,857	0,885	0,906	0,897
100	0,857	0,873	0,865	0,884	0,930	0,912	0,774	0,916	0,877
110	0,898	0,906	0,902	0,927	0,945	0,938	0,844	0,899	0,877
120	0,857	0,871	0,864	0,889	0,912	0,902	0,889	0,919	0,906
130	0,896	0,896	0,896	0,951	0,954	0,952	0,821	0,833	0,828
140	0,931	0,943	0,938	0,923	0,921	0,922	0,931	0,939	0,935
150	0,898	0,902	0,900	0,935	0,944	0,940	0,824	0,816	0,820
160	0,933	0,938	0,935	0,981	0,980	0,981	0,923	0,915	0,919
170	0,893	0,906	0,900	0,915	0,925	0,921	0,909	0,921	0,915
180	0,880	0,889	0,885	0,800	0,840	0,822	0,945	0,947	0,946
190	0,927	0,947	0,939	0,923	0,929	0,926	0,889	0,875	0,882
200	0,816	0,830	0,824	0,810	0,778	0,795	0,851	0,857	0,854
220	0,750	0,733	0,742	0,909	0,919	0,914	0,813	0,842	0,829
240	0,640	0,710	0,679	0,839	0,872	0,857	0,688	0,762	0,730
260	0,750	0,800	0,778	0,643	0,688	0,667	0,909	0,919	0,914

APÊNDICE C – Matriz de Confusão em diferentes altura e horizontes de tempo

Tabela 25 – Matriz de confusão para diferentes alturas e tempos no ponto P0.

Altura	Tempo 10 (min)				Tempo 20 (min)				Tempo 30 (min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
40	54	3	2	56	51	0	2	45	50	1	2	46
50	64	2	2	56	51	5	1	46	53	3	0	50
60	63	2	1	63	52	1	2	49	48	5	1	45
70	61	2	2	63	50	4	2	45	49	2	2	49
80	62	1	1	59	53	3	2	52	56	4	2	41
90	66	1	2	62	49	1	3	50	52	1	3	54
100	61	1	3	63	50	0	2	49	51	1	3	47
110	66	2	1	60	51	1	1	44	57	1	3	49
120	58	0	2	66	46	1	1	54	50	1	2	39
130	66	3	1	58	51	2	0	42	52	2	0	39
140	66	2	1	56	46	1	2	50	45	2	4	41
150	62	4	0	54	55	3	2	44	47	1	1	38
160	54	1	2	54	45	0	4	45	43	3	4	38
170	61	3	0	53	42	1	1	41	37	0	3	33
180	54	3	0	48	38	3	0	37	42	0	1	37
190	60	1	4	49	42	1	1	38	42	2	1	34
200	51	0	1	51	40	1	0	35	39	0	1	38
220	46	2	1	46	35	2	0	32	29	1	1	28
240	45	1	2	43	30	0	2	33	28	5	0	22
260	41	2	1	40	24	2	1	22	26	1	1	21

Altura	Tempo 40 (min)				Tempo 50 (min)				Tempo 60 (min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
40	53	2	2	44	52	2	2	48	53	2	1	56
50	53	2	1	44	45	3	1	43	52	4	2	48
60	59	1	2	52	43	3	2	45	53	1	0	50
70	51	4	2	49	56	3	0	43	54	1	1	50
80	57	1	2	46	44	0	4	53	56	1	0	46
90	46	3	4	50	52	3	2	50	53	1	2	51
100	54	2	3	42	52	0	3	51	53	4	1	48
110	51	3	3	46	50	0	2	44	46	0	0	51
120	45	2	1	47	54	0	0	57	51	2	0	43
130	46	1	1	41	58	2	1	43	44	0	4	44
140	49	0	3	47	50	2	1	40	44	2	1	44
150	46	1	4	41	47	0	1	44	50	3	1	38
160	46	1	2	43	49	1	2	38	44	3	1	41
170	49	1	1	38	42	1	2	39	43	2	0	37
180	42	1	2	40	46	2	0	45	42	0	0	38
190	36	1	1	35	39	1	2	41	40	1	1	32
200	39	1	0	33	37	3	0	30	35	1	1	30
220	27	1	1	25	28	1	3	30	33	2	0	27
240	29	1	3	28	23	2	6	24	26	3	2	22
260	19	1	4	21	23	2	3	24	27	2	2	23

Tabela 26 – Matriz de confusão para diferentes alturas e tempos no ponto P1.

Altura	Tempo 10 (min)				Tempo 20 (min)				Tempo 30 (min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
40	79	0	1	81	58	2	0	57	57	0	1	42
50	72	1	0	81	62	1	0	41	39	2	1	40
60	85	0	0	69	46	0	0	50	44	3	0	36
70	69	0	0	68	41	0	0	50	33	0	1	32
80	70	0	1	66	46	0	1	47	41	0	0	36
90	65	0	4	62	41	1	2	43	37	3	0	34
100	61	1	0	67	42	1	0	39	33	0	2	36
110	62	0	0	57	41	3	0	35	34	2	1	29
120	60	0	0	59	33	0	1	33	34	1	1	32
130	59	1	1	53	35	1	0	34	33	1	0	38
140	57	1	2	58	33	1	0	34	30	1	0	27
150	63	0	0	59	34	1	1	33	32	1	1	33
160	60	0	0	60	33	0	0	35	31	0	1	32
170	52	1	1	57	37	0	2	38	25	1	1	28
180	55	1	0	55	33	1	2	37	26	1	1	25
190	50	0	3	54	30	1	2	32	29	1	2	30
200	51	1	2	53	28	0	0	28	28	2	1	26
220	50	0	1	48	32	1	1	29	22	0	1	20
240	40	1	3	45	25	2	2	26	15	2	1	15
260	43	1	0	39	24	0	1	25	12	1	1	17

Altura	Tempo 40 (min)				Tempo 50 (min)				Tempo 60 (min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
40	44	2	1	33	39	0	0	35	40	3	1	18
50	34	0	1	31	30	1	1	30	45	2	2	22
60	31	1	2	31	29	1	1	28	40	2	0	29
70	30	2	1	24	33	0	1	27	31	3	0	24
80	33	2	0	28	34	0	0	30	27	0	2	29
90	36	1	0	21	38	0	1	22	29	0	3	35
100	36	1	0	24	37	1	2	31	31	1	1	26
110	26	0	2	25	31	1	1	25	32	1	0	26
120	34	1	0	30	32	1	1	29	29	0	2	40
130	32	2	0	28	31	0	2	28	32	0	1	34
140	30	0	2	36	28	0	1	31	29	1	3	29
150	32	0	1	29	26	1	0	31	27	1	1	35
160	27	0	5	32	25	0	4	30	29	2	1	29
170	30	1	1	28	24	1	2	26	25	1	2	29
180	28	1	1	25	24	0	3	29	26	1	4	27
190	26	2	1	22	28	0	2	27	26	0	1	27
200	27	2	1	29	28	1	2	26	21	1	2	24
220	22	1	1	22	21	0	3	23	18	0	1	20
240	14	1	4	17	15	0	1	17	10	2	3	13
260	14	0	3	12	13	0	2	13	14	0	1	12

Tabela 27 – Matriz de confusão para diferentes alturas e tempos no ponto P2.

Altura	Tempo 10 (min)				Tempo 20 (min)				Tempo 30 (min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
40	187	1	0	213	159	1	1	149	133	1	0	132
50	178	0	4	198	148	2	0	130	125	1	2	133
60	196	2	0	184	143	1	0	133	134	4	1	109
70	200	2	0	169	138	2	1	130	133	1	0	123
80	192	1	0	165	141	2	0	133	116	1	4	125
90	163	0	0	184	146	1	1	134	133	1	0	122
100	174	1	2	164	132	1	0	130	122	1	1	120
110	174	1	0	165	132	1	1	131	119	0	1	118
120	173	1	3	171	132	4	0	128	129	0	3	116
130	166	2	1	170	143	1	0	131	124	0	1	123
140	176	0	0	177	139	4	3	118	119	3	1	115
150	165	1	2	174	132	6	1	122	116	4	1	116
160	162	2	4	169	136	2	1	108	116	3	3	114
170	169	1	1	149	129	4	2	115	104	2	3	110
180	169	1	2	151	120	4	3	108	111	2	2	101
190	156	1	0	150	116	5	1	112	100	2	2	89
200	158	1	2	144	115	2	0	102	90	0	1	87
220	152	1	0	131	99	2	0	98	78	1	0	72
240	138	0	2	129	94	3	1	89	74	2	1	75
260	122	1	0	131	101	0	2	98	76	5	1	74

Altura	Tempo 40 (min)				Tempo 50 (min)				Tempo 60 (min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
40	147	1	1	148	132	4	0	135	146	1	0	142
50	144	0	0	135	143	1	0	144	145	0	0	150
60	136	1	2	136	153	2	0	144	143	0	1	140
70	136	0	1	135	134	0	2	127	140	0	0	139
80	144	1	0	131	134	0	1	129	145	2	1	146
90	141	1	1	127	136	1	0	133	149	1	1	131
100	131	1	0	139	138	1	0	126	139	1	0	142
110	132	0	2	136	127	0	1	132	137	2	1	136
120	124	2	2	133	133	0	3	127	137	0	0	136
130	123	0	0	121	126	0	1	127	135	2	0	130
140	120	3	1	113	126	2	0	131	130	1	4	122
150	124	3	3	115	120	1	2	120	133	3	0	125
160	120	1	2	114	117	1	0	116	126	2	1	115
170	111	3	1	108	108	1	2	110	120	3	1	129
180	105	3	1	104	104	0	1	114	111	2	0	115
190	96	0	0	101	99	0	2	114	119	2	1	113
200	86	3	1	99	88	1	0	101	108	0	1	105
220	77	0	1	86	88	1	0	83	86	3	3	82
240	76	4	0	68	72	1	2	89	81	0	0	83
260	79	1	1	68	67	2	3	71	83	2	1	76

Tabela 28 – Matriz de confusão para diferentes alturas e tempos no ponto P6.

Altura	Tempo 10 (min)				Tempo 20 (min)				Tempo 30 (min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
40	112	0	0	132	91	2	0	78	74	0	0	63
50	115	1	1	115	84	2	2	83	77	1	0	67
60	102	0	2	101	81	3	2	73	69	1	1	57
70	122	4	0	84	73	0	3	76	62	0	1	54
80	103	1	1	93	67	1	1	66	62	0	2	48
90	101	2	1	90	61	0	1	60	55	1	0	44
100	90	1	2	88	68	1	1	72	50	2	1	45
110	87	1	1	88	67	1	3	60	51	1	2	44
120	90	0	2	82	71	0	1	58	49	1	1	44
130	92	1	0	95	71	0	0	61	57	1	1	38
140	101	1	0	81	63	1	1	59	52	1	2	40
150	85	2	1	94	59	0	1	60	49	2	0	44
160	99	1	0	86	65	0	0	66	45	4	1	39
170	97	1	2	84	65	0	1	60	50	0	2	50
180	81	0	0	84	63	2	0	56	45	1	2	44
190	92	1	1	75	67	0	0	61	47	2	1	42
200	87	1	0	78	57	0	1	52	48	3	1	34
220	88	2	0	68	54	0	0	54	48	1	0	32
240	82	0	1	68	45	1	1	52	39	2	2	39
260	77	0	0	63	48	1	0	49	40	2	2	36

Altura	Tempo 40 (min)				Tempo 50 (min)				Tempo 60 (min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
40	70	2	0	58	75	2	0	66	63	1	3	58
50	70	0	1	58	62	3	1	60	53	1	2	61
60	64	1	1	45	55	1	3	56	74	3	2	37
70	52	2	2	46	58	0	0	52	61	0	0	49
80	53	4	1	44	44	3	3	45	65	3	1	37
90	47	0	2	44	45	2	2	39	54	1	2	38
100	42	1	2	41	47	3	1	30	54	1	2	42
110	42	4	2	42	38	2	3	42	54	2	3	35
120	50	1	1	44	47	4	2	35	49	5	2	31
130	46	0	1	51	42	0	3	34	47	0	2	39
140	49	1	2	45	46	2	4	34	46	2	1	35
150	46	3	1	36	42	0	0	43	49	0	0	37
160	49	1	1	42	43	1	0	40	48	2	1	43
170	48	2	2	39	40	0	0	37	38	1	1	37
180	48	3	1	43	46	0	1	45	41	1	3	39
190	39	2	2	43	30	0	2	41	45	2	2	37
200	41	5	1	35	36	0	0	38	41	1	1	37
220	48	2	1	36	35	0	0	32	35	2	1	33
240	36	2	0	34	30	2	1	25	31	2	3	30
260	29	2	2	34	27	1	0	26	30	2	2	30

Tabela 29 – Matriz de confusão para diferentes alturas e tempos no ponto P7.

Altura	Tempo 10 (min)				Tempo 20 (min)				Tempo 30 (min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
40	80	1	1	56	52	2	1	44	42	1	1	34
50	68	1	5	65	43	6	2	39	42	1	4	38
60	68	0	2	70	41	0	3	47	39	1	3	38
70	59	2	4	66	46	3	1	40	35	8	3	29
80	69	3	4	63	46	4	1	36	35	1	2	33
90	66	3	1	62	38	3	0	39	35	3	0	26
100	63	3	0	57	43	5	2	36	32	1	2	29
110	61	2	0	59	43	1	1	45	38	5	1	19
120	59	1	1	64	37	1	1	39	28	3	2	28
130	67	0	0	63	38	4	2	35	26	2	0	26
140	55	1	1	62	45	3	0	34	26	2	4	31
150	61	1	1	53	35	4	1	32	38	3	1	26
160	55	3	2	57	36	2	0	31	26	5	5	25
170	60	2	1	55	37	1	1	37	27	2	1	32
180	52	2	0	55	32	6	3	28	26	2	1	21
190	53	3	4	48	38	5	0	25	28	6	1	23
200	55	3	2	50	29	1	4	33	23	5	1	14
220	50	2	3	46	28	2	3	30	16	3	2	13
240	42	2	1	42	22	5	3	19	14	2	2	14
260	37	3	0	35	24	4	3	18	16	4	2	10

Altura	Tempo 40 (min)				Tempo 50 (min)				Tempo 60 (min)			
	VP	FN	FP	VN	VP	FN	FP	VN	VP	FN	FP	VN
40	40	2	3	30	47	4	3	24	41	7	4	18
50	41	4	1	26	40	5	2	20	39	6	0	23
60	43	3	4	32	31	2	3	28	37	2	3	32
70	42	1	2	25	40	4	1	19	31	1	4	23
80	29	4	3	27	38	3	3	24	40	5	2	20
90	30	4	1	16	24	2	6	24	29	3	3	23
100	24	2	5	21	33	2	3	19	38	7	0	12
110	24	3	2	22	26	2	1	19	31	5	2	19
120	27	6	2	24	31	6	0	24	34	4	2	24
130	30	3	4	30	31	1	2	29	25	6	4	23
140	33	4	0	27	29	4	1	30	31	3	1	27
150	23	2	3	22	34	3	1	29	20	5	4	21
160	30	3	1	28	25	1	0	26	27	3	2	30
170	29	5	1	25	31	4	1	27	29	1	4	25
180	24	3	3	22	21	5	3	16	27	1	2	26
190	27	3	0	19	26	2	2	24	21	1	5	24
200	22	5	4	20	14	2	6	17	21	5	2	20
220	11	6	2	12	17	2	1	15	16	4	2	13
240	11	4	5	8	17	4	1	13	16	5	5	11
260	12	2	4	9	11	5	5	9	17	2	1	15